

Universidade Federal de Santa Catarina  
Programa de Pós-Graduação em  
Engenharia de Produção

**IDENTIFICAÇÃO DE PADRÕES EM  
GRÁFICOS DE CONTROLE  
ESTATÍSTICO DE PROCESSOS, EM  
TEMPO REAL, UTILIZANDO SÉRIES  
TEMPORAIS E REDES NEURAIS  
ARTIFICIAIS**

**Pedro Paulo Balestrassi**

Tese apresentada ao  
Programa de Pós-Graduação em  
Engenharia de Produção da  
Universidade Federal de Santa Catarina  
como requisito parcial para obtenção  
do título de Doutor em  
Engenharia de Produção

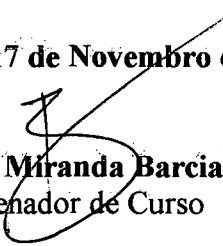
**Florianópolis  
2000**

Pedro Paulo Balestrassi

**IDENTIFICAÇÃO DE PADRÕES EM GRÁFICOS DE CONTROLE  
ESTATÍSTICO DE PROCESSOS, EM TEMPO REAL, UTILIZANDO SÉRIES  
TEMPORAIS E REDES NEURAIS ARTIFICIAIS.**

**Esta tese foi julgada e aprovada para a obtenção do título de Doutor em Engenharia  
de Produção no Programa de Pós-graduação em Engenharia de Produção da  
Universidade Federal de Santa Catarina.**

**Florianópolis, 17 de Novembro de 2000**

  
**Prof.: Ricardo Miranda Barcia, Ph.D.**  
Coordenador de Curso

**BANCA EXAMINADORA:**

  
**Prof.: Robert Wayne Samohyl, Ph.D.**  
Orientador

  
**Prof.: Silvia Nassar, Dr.<sup>a</sup>.**  
Moderadora

  
**Prof.: César Octávio Malayé, Ph.D.**

  
**Prof.: Luiz Eduardo Borges da Silva, Ph.D.**

  
**Prof.: Roberto C. S. Pacheco, Dr.**

  
**Prof.: José Leomar Todesco, Dr.**

  
**Prof.: Alejandro Martins, Dr.**

## ***Agradecimentos***

---

Ao Prof. Samohyl, meu orientador, pelo incentivo, motivação e pelo espírito jovem de buscar caminhos novos.

Ao amigo César Malavé e sua grande família por tornar a minha passagem na Texas A&M University uma experiência fundamental. Thanks a lot!

Ao amigo Adriano, pelos anos de convivência perseguindo similares ideais.

Aos amigos Wesley, João Cândido, Anderson, Hamilton e José Leonardo que tornaram minha estadia em Florianópolis um lugar mais que oportuno.

Aos amigos Suzan e John Karine, Debra Elkins e Richard Marek, meus "reais" professores de inglês.

Aos amigos Gonzaga e Pamplona e a todo o Departamento de Engenharia de Produção da EFEI que, sem exceção, esteve sempre me apoiando.

Ao meu irmão Luiz Calistro e ao pessoal da Neurotec, que não deixaram a pesquisa rumar somente pelos caminhos teóricos e acadêmicos.

A CAPES, pelo importante suporte financeiro, subsidiando a pesquisa.

Aos meus pais, Pedro e Tereza, sempre comigo, mesmo distantes.

Finalmente e mais importante, a minha esposa Márcia e meus filhos Lucas e Marina por aceitarem caminhos desconhecidos com muita coragem.

## Sumário

---

Lista de figuras .....	vi
Lista de tabelas .....	viii
Lista de reduções .....	x
Resumo .....	xii
Abstract.....	xiii
1. INTRODUÇÃO	
1.1 Introdução .....	1
1.2 Descrição do problema .....	5
1.3 Objetivos da pesquisa .....	7
1.4 Organização e metodologia do trabalho .....	10
2. REVISÃO DA LITERATURA	
2.1 Introdução .....	11
2.2 Padrões em CEP .....	11
2.3 CEP em tempo real .....	15
2.4 Inteligência artificial e CEP .....	21
2.5 Reconhecimento de padrões em CEP .....	24
2.6 MODELAMENTO DE DADOS EM TEMPO REAL	
2.7 Introdução .....	29
2.8 Modelos univariados .....	31
2.9 Análise de resultados .....	36
3. REDES NEURAIS ARTIFICIAIS	
3.1 Introdução .....	41
3.2 O que são as redes neurais artificiais .....	41
3.3 Modelo do neurônio artificial .....	46
3.4 Topologias das RNs .....	48
3.5 O aprendizado nas RNs .....	50
3.6 Classificação de padrões .....	53
3.7 Uma pequena análise de resultados da literatura .....	53

4. RECONHECIMENTO NEURAL DE PADRÕES EM CEP	
4.1 Introdução .....	55
4.2 Técnicas convencionais, sistemas especialistas e RNs.....	56
4.3 Construção do banco de dados .....	59
4.4 Padrões Cíclicos .....	70
4.5 Experimentos iniciais com a rede Fuzzy-ARTMAP .....	72
4.6 Experimentos com a rede RBF .....	81
4.7 Análise de resultados .....	96
5. APLICAÇÃO: RECONHECIMENTO DE PADRÕES DA ATIVIDADE EEG	
5.1 Introdução .....	111
5.2 Sinais EEG.....	112
5.3 Caracterização do problema .....	114
5.4 Desenvolvimento .....	116
5.5 Resultados e considerações .....	126
6. CONCLUSÃO	
6.1 Introdução .....	135
6.2 Desenvolvimento e contribuição .....	135
6.3 Discussões e desenvolvimentos Futuros .....	145
6.4 Conclusões.....	151
BIBLIOGRAFIA .....	153
ANEXOS	
A. Geração dos padrões.....	160
B. Mínimos quadrados ortogonais .....	162
C. Código de programa .....	166
D. Publicação: Números difusos na análise do sinal EEG .....	179
E. Publicação: Inteligência artificial aplicada ao CEP em sistemas automatizados de manufatura .....	192
F. Publicação: Métodos de previsão usando a série econométrica de Nelson-Plosser: um estudo comparativo .....	205

## ***Lista de Figuras***

---

1.1: Contexto to CEP .....	1
1.2: Representação de uma carta de controle de Shewhart.....	2
1.3: Acurácia e precisão.....	2
1.4: Runs Tests clássico.....	3
1.5: Metodologia proposta.....	8
2.1: Padrões não aleatórios de CEP .....	14
2.2: Representação de zonas em uma carta de controle.....	14
2.3: Sistema de CEP para um ambiente de manufatura automatizado .....	17
2.4: Agente do tipo reflexo simples.....	22
2.5: Exemplo de tendência de uma carta de controle de um processo .....	23
2.6: Representação dos passos em um reconhecimento de padrões .....	24
3.1: Série de um processo em tempo real .....	33
3.2: Série de resíduos correspondente a 3.1.....	33
3.3: Série de temperaturas .....	37
3.4: Função ACF da série de temperaturas.....	37
3.5: Função PACF da série de temperaturas.....	38
3.6: Resíduos da série de temperaturas.....	38
3.7: Função ACF dos resíduos da série de temperaturas .....	39
3.8: Resíduos de um modelo AR(2) .....	39
3.9: Função ACF para AR(2) .....	39
4.1: Modelo de neurônio artificial .....	47
4.2: Uma RN de camada única .....	49
4.3: Uma rede feedforward multicamada .....	50
5.1: Geração dos padrões normais de treinamento .....	63
5.2: Geração de amostras normalmente distribuídas .....	64
5.3: Exemplo de gráfico de Shewhart para pontos individuais .....	65
5.4: Esquema do cálculo de médias e desvios.....	66
5.5: Gráfico de controle CUSUM usando máscara V.....	67
5.6: Gráfico de controle CUSUM usando forma tabular.....	67

5.7: Deslocamento da janela de pontos .....	69
5.8: Exemplos de padrões cíclicos com vários períodos .....	70
5.9: Experimentos com a rede Fuzzy ARTMAP .....	73
5.10: Estrutura da rede Fuzzy ARTMAP .....	76
5.11: Tela de trabalho do programa The Art Gallery .....	79
5.12: Resultados do The Art Gallery para o problema de identificação.....	80
5.13: Característica dos espaços das redes Backpropagation e RBFN.....	82
5.14: Arquitetura da RBFN .....	83
5.15: Histogramas dos resultados do reconhecimento de padrões .....	109
6.1: Sinal EEG .....	112
6.2: Sinal EEG computadorizado obtido usando o SI 10-20.....	113
6.3: Alguns exemplos de sinais patológicos.....	115
6.4: Artefatos que contaminam a atividade EEG.....	116
6.5: Hardware básico utilizado.(Neuromap/Neurotec).....	117
6.6: Vídeo EEG digital .....	118
6.7: Síntese do reconhecimento de padrões feito sobre o sinal EEG.....	119
6.8: Caracterização das faixas de frequência do traçado EEG .....	120
6.9: Passos do reconhecimento dos padrões da atividade EEG.....	121
6.10: SI 10-20 .....	122
6.11: Resultados gráficos de saída da rede neural em tempo real .....	126
6.12: Histogramas dos resultados do reconhecimento de padrões .....	130
6.13: Monitor cerebral mostrando os Descritores de Hjorth .....	134

## ***Lista de Tabelas***

---

2.1: Regras suplementares (Western Electric).....	14
2.2: Regras suplementares (Grant/Leavenworth) .....	15
2.3: Regras suplementares (Nelson).....	15
2.4: Um agente e sua descrição em termos de IA.....	21
2.5: As propriedades do ambiente do agente.....	22
4.1: Terminologia correspondente entre estatística e redes neurais .....	45
5.1: Resultados de Pham e Oztemel .....	57
5.2: Resultados de Tontini.....	57
5.3: Resultados de Smith.....	57
5.4: Resultados de Guo e Dooley .....	58
5.5: Valores dos parâmetros usados para as diversas classes de padrões .....	60
5.6: Erros tipo I e tipo II .....	61
5.7: Representação inicial dos padrões.....	68
5.8: Banco de dados de treinamento para a rede Fuzzy-ARTMAP.....	73
5.9: ARL para desvios da média usando vários métodos .....	97
5.10: Agrupamento dos experimentos com a rede RBF .....	98
5.11: Desempenho da rede RBF para tendência crescente .....	100
5.12: Desempenho da rede RBF para tendência decrescente .....	101
5.13: Desempenho da rede RBF para ciclos .....	102
5.14: Desempenho da rede RBF para padrão sistemático .....	103
5.15: Desempenho da rede RBF para padrões de estratificação.....	104
5.16: Desempenho da rede RBF para padrões de mistura .....	105
5.17: Desempenho da rede RBF para deslocamento positivo da média.....	106
5.18: Desempenho da rede RBF para deslocamento negativo da média.....	107
5.19: Análise de Variância para a taxa de acertos $R_t$ .....	108
5.20: Comparação de resultados com respostas de especialistas .....	110
6.1: Padrões utilizados na aplicação envolvendo o vídeo EEG digital .....	119
6.2: Erros tipo I e tipo II para a tomada de decisão do traçado EEG.....	125
6.3: Artefatos de Eletrodos .....	127
6.4: Ondas Trifásicas .....	128



6.5: Artefatos de Eletrocardiograma.....	128
6.6: Pleds .....	129
6.7: Spikes .....	129
6.8: Falsos Alarmes (%) .....	129
6.9: Modelo Geral.....	131
6.10: Vigília.....	131
6.11: Hiperpnéia .....	132
6.12: Foto Estimulo .....	132
6.13: Áudio Estimulo.....	132
6.14: Sono.....	132
7.1: Comparação das características da aproximação.....	148

## ***Lista de Reduções***

---

A/D	Analógico/Digital
ACF	<i>Autocorrelation Function</i>
AIC	<i>Akaike Information Criterion</i>
ANOVA	<i>Analysis of Variance</i>
APC	<i>Automatic Process Control</i>
AR	<i>Autoregressive</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARL	<i>Average Run Length</i>
ARLt	<i>Average Run Length Target</i>
ARLtx	<i>Average Run Length Target Index</i>
ARMA	<i>Autoregressive Moving Average</i>
ARMAQS	<i>Autoregressive Moving Average Q-Slice</i>
ARMARTS	<i>Autoregressive Moving Average Residual Time Series</i>
ARORDER	<i>Autoregressive Order</i>
ART	<i>Adaptive Resonance Theory</i>
BIC	<i>Bayesian Akaike Information Criterion</i>
CAT	<i>Parzen's CAT Criterion</i>
CCO	Curva Característica de Operação
CEP	Controle Estatístico de Processos
CUSUM	<i>Cumulative Sum</i>
DSP	<i>Digital Signal Processing</i>
EEG	Eletrencefalograma
FFT	<i>Fast Fourier Transform</i>
FPE	<i>Final Prediction Error</i>
IA	Inteligência Artificial
IID	Identicamente e Independentemente Distribuído
LVQ	<i>Learning Vector Quantization</i>
MA	<i>Moving Average</i>
MAORDER	<i>Moving Average Order</i>
MDL	<i>Minimal Description Lenth Criterion</i>

OLS	<i>Orthogonal Least Square</i>
PACF	<i>Partial Autocorrelation Function</i>
PHI	<i>Critério Phi de Pukila</i>
RBF	<i>Radial Basis Function</i>
RBFN	<i>Radial Basis Function Network</i>
RL	<i>Run Length</i>
RN	<i>Rede Neural</i>
Rnt	<i>Rate of Non Target</i>
RONs	<i>Rate of Non Shift</i>
ROS	<i>Rate of Shift</i>
Rt	<i>Rate of Target</i>
SBC	<i>Schwartz's Bayesian Criterion</i>
SI 10-20	<i>Sistema International 10-20</i>
SSE	<i>Sum-squared error</i>

## Resumo

---

BALESTRASSI, Pedro Paulo. **Identificação de padrões em gráficos de controle estatístico de processos, em tempo real, utilizando séries temporais e redes neurais artificiais.** Florianópolis, 2000. 216f. Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina.

O presente trabalho procurou implementar um sistema semi-automatizado de Controle Estatístico de Processos (CEP) para dados obtidos em tempo real. Tal sistema abrange um grande escopo de aplicações pois aplica-se tanto para processos serialmente correlacionados como para processos identicamente e independentemente distribuídos (iid). No sistema proposto, os dados são obtidos a partir de sensores em um processo automatizado qualquer. Em seguida esses dados são modelados e são gerados um conjunto de resíduos. Sobre esses resíduos atua uma rede neural, treinada *off line*, que faz o reconhecimento de padrões de uma carta de controle estatístico de processos em tempo real. O processo pode ser a qualquer momento remodelado para uma nova série de dados ou escolhendo-se um modelo testado anteriormente. Tal sistema foi parcialmente testado em relação a sistemas convencionais e várias medidas de desempenho mostraram resultados satisfatórios. Todo o sistema foi inteiramente simulado por computador e as rotinas computacionais são disponibilizadas para futuros aperfeiçoamentos e comparações. Uma aplicação real foi avaliada abordando um problema de reconhecimento de padrões da atividade eletrencefalográfica do cérebro.

## **Abstract**

---

**BALESTRASSI, Pedro Paulo. Identificação de padrões em gráficos de controle estatístico de processos, em tempo real, utilizando séries temporais e redes neurais artificiais.** Florianópolis, 2000. 216f. Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina.

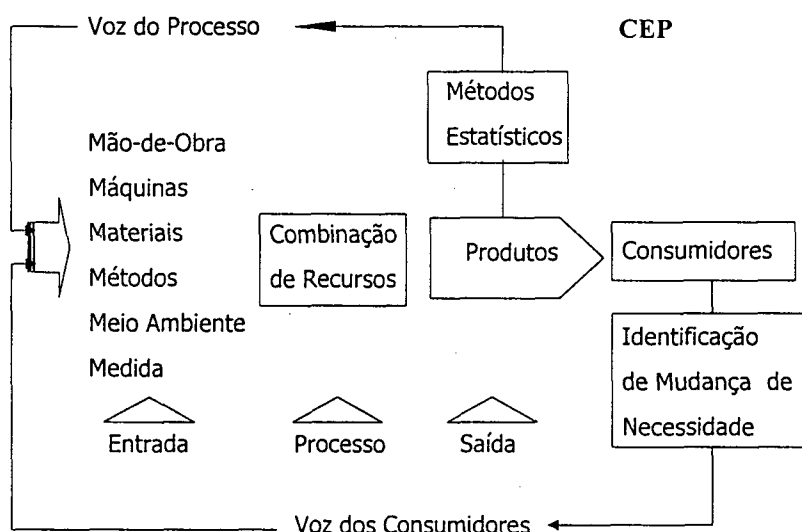
This research describes an implementation of a real time statistical process control (SPC) system. A great scope of applications is related to this system because it can be used to analyze autocorrelated processes as well as independent and identically distributed (iid) processes. In this proposed system, data is obtained by sensors in an automated process. The data is modeled and a residual set is generated. A neural network, which is trained offline, acts over this residual set and is responsible for the pattern recognition of a SPC in real time. The process can be remodeled at anytime with the introduction of a new data set or a previously developed model. This system was partially tested in relation to conventional systems and some performance measures have indicated that results are positive. The whole system was simulated and the computational procedures are available for future research. A application, related to electrencephalography signal activity (EEG) pattern recognition, was also evaluated.

## Capítulo 1 – Introdução

### 1.1 Introdução

A figura 1.1 mostra o contexto do Controle Estatístico de Processos (CEP) em um processo genérico de manufatura. Nesse contexto, o CEP pode ser considerado como sendo o mais importante método estatístico capaz de representar a voz de todo o processo.

**Figura 1.1: Contexto to CEP em Processos de Manufatura.**




Fonte: Western Electric (1958)

As mais importantes e também as mais conhecidas ferramentas do CEP são consideradas as Cartas de Controle. Elas são úteis em determinar se um processo está se comportando como desejado ou se existem algumas causas não aleatórias de variação interagindo no processo. Um processo é considerado estar fora de controle quando um ponto (por exemplo, uma medida obtida de um sensor em um processo de manufatura automatizado) situa-se fora dos chamados limites de controle ou uma série de pontos exibem um comportamento não natural (também conhecido como padrão não aleatório). Na figura 1.2 está representada uma carta de controle convencional (carta de Shewhart)


com os seus limites de controle e a distribuição de probabilidade na qual ela teve a sua origem.

**Figura 1.2: Representação de uma carta de controle de Shewhart.**



A análise dos padrões não aleatórios é um dos mais relevantes aspectos do CEP. Esses padrões fornecem valiosas informações relacionadas com a melhoria de um processo. Existe uma vasta literatura técnica sobre tais padrões que associam freqüentemente um conjunto específico de causas assinaláveis a um determinado padrão não aleatório em uma carta de controle. A identificação desses padrões pode fortemente estreitar o conjunto de causas que devem ser investigadas em possíveis problemas e assim o tempo de diagnóstico pode ser substancialmente reduzido. De uma maneira geral, pode-se dizer que um processo está sob controle quando os pontos em uma carta de controle são definidos como precisos e acurados, como mostra a figura 1.3.


**Figura 1.3: Acurácia e precisão.**



Desde a sua formal concepção em 1924 por Walter Shewhart, numerosas regras suplementares conhecidas como *Runs Tests* ou *Zone Tests* (Western Electric, 1958;

Nelson, 1985) tem sido propostas para analisar as cartas de controle. A figura 1.4 mostra um desses conjuntos de regras clássicas. Essas regras foram desenvolvidas para assistir os operadores na detecção de padrões não aleatórios. Contudo, a interpretação dos dados de uma carta de controle ainda permanece difícil pois isso envolve aspectos de reconhecimento de padrões que freqüentemente leva em consideração a experiência do analista em determinar se um padrão não aleatório existe ou não.

**Figura 1.4: *Runs Tests* clássico.**



- 1) 1 ponto acima do limite de controle
- 2) 2 pontos em 3 consecutivos acima de 2 desvios
- 3) 4 pontos em 5 consecutivos acima de 1 desvio
- 4) 7 pontos consecutivos além da linha média
- 5) 6 pontos consecutivos crescentes ou decrescentes
- 6) 8 pontos crescentes ou decrescentes em 10
- 7) 2 pontos consecutivos com diferença de 4 desvios

Em um ambiente produtivo a variação é considerada, com justiça, como uma inimiga de todos os processos. Tal variação ocorre de pessoa para pessoa, nas partes de um processo, no tempo, nos projetos, meio ambiente, etc. E existem inevitavelmente os custos associados a tais variações desde que elas podem provocar rupturas na produção ou desencadear uma perda de qualidade nos produtos finais.

O CEP ocupa um lugar de destaque no gerenciamento da qualidade de processos produtivos, no trato com essas variações. Em termos científicos o CEP teve um grande avanço nos últimos anos. Os recursos computacionais disponíveis criaram novos horizontes de pesquisa, novos projetos de cartas de controle foram concebidos, associações e revistas especializadas foram criadas e, acima de tudo, um grande número de publicações vieram a tona. Ho e Case (1994) traçam um histórico da literatura existente de 1981 a 1991 e de lá para cá também muita coisa tem acontecido. O



envolvimento de metodologias como Redes Neurais, Reconhecimento de Padrões e Conjuntos Difusos, criaram siglas como CCPR (*Control Chart Pattern Recognizer*), APC (*Automatic Process Control*), Cartas de Controle NF (*Neural Fuzzy*), além da enorme interação proporcionada por tais metodologias. Procedimentos de Séries Temporais, Filtros de Kalman, Ondaletas, *Clusters*, Estatística Multivariada, Cartas Combinadas, DNOM, entre outros, podem ser melhor estudados em tal revisão.

Apesar do inquestionável avanço acadêmico, a contrapartida em termos práticos teve pouca mudança desde sua concepção. Hoyer & Ellis (1996), descrevem que se ocorresse um reaparecimento milagroso de Shewhart em nossos dias, e não considerando a sua privilegiada inteligência, ele pouco teria que aprender com os avanços práticos decorrentes de sua criação em meados de 1920. Nos polêmicos trabalhos de Alwan & Roberts (1995) e Caulcutt (1996), publicados conjuntamente no periódico *Applied Statistics* e submetidos a discussão, os autores apontam os problemas mais freqüentes encontrados na utilização das Cartas de Controle, e a despeito de esperarem um resultado positivo em função de uma experiência tendenciosa, encontram o insignificante resultado de 14% (dentre as 235 cartas de controle investigadas) que apresentam gráficos que não violam conceitos estatísticos básicos. Também nesses trabalhos, são questionadas as práticas já sedimentadas dos *runs tests*, os pacotes computacionais existentes no mercado, o esforço enorme para se combater os 6% apenas de causas especiais, entre outros problemas.

O que se pode facilmente perceber é que as técnicas mais sofisticadas de CEP não tem atingido de forma consistente os diversos processos industriais, ficando sua utilização restrita a aplicações em que um especialista em CEP define o seu emprego, na maioria das vezes em processos não automatizados. As cartas convencionais, quando bem empregadas, traduzem o seu emprego em melhorias imediatas atuando a nível de causas especiais e em um melhor conhecimento do processo por parte dos usuários. Quando mal empregadas as cartas convencionais acabam por despender recursos e fornecer uma má interpretação da estabilidade de um processo, sendo seus resultados talvez piores que o seu não emprego.

Um outro ponto é que as cartas convencionais, mesmo bem empregadas, são de uso limitado quando atuantes por si só. Os *runs tests* clássicos, com a sua simplicidade, não são capazes de controlar a variabilidade de toda a gama de processos de uma forma definitiva. E isso verdadeiramente não é e nunca foi a sua intenção. A combinação de metodologias deve ser a tônica dos próximos avanços práticos em CEP. E isso está relacionado com um maior treinamento dos especialistas em utilizar alguns recursos mais sofisticados. A máxima de Ishikawa: “qualidade começa com treinamento e termina com treinamento” é a maior verdade também para os especialistas que atuam em CEP.

## 1.2 Descrição do Problema

Nessa pesquisa será considerado o problema de detecção de mudanças na distribuição de variáveis aleatórias serialmente correlacionadas. Por exemplo: considere a medição da coloração da polpa de papel quando ele passa em um sensor óptico. Se o processo está ocorrendo corretamente, espera-se que as observações tenham uma média fixa com um desvio padrão em torno dessa média. Essa variabilidade é inerente a todos os processos. Em situações anormais (produtos ruins, erro de operadores, etc....) uma fonte de variabilidade alternativa é então introduzida e a distribuição de probabilidade do processo corrente é alterada. Se a distribuição do processo é constante com o tempo pode-se dizer que o processo está sob controle; em caso contrário o processo está fora de controle. Quando a distribuição do processo muda, deseja-se detectar essa mudança rapidamente e determinar a causa física da mudança.

Uma importante motivação dessa pesquisa é o crescente interesse em sistemas de manufatura inteligentes. Em tais sistemas, sensores e transdutores são usados para capturar os dados de um processo qualquer e uma rápida interpretação torna-se essencial. Nesse caso, deseja-se que a análise dos dados deva ser feita em tempo real com pequena ou nenhuma intervenção humana. Nesse ambiente, o processo é monitorado por um computador em tempo real. O operador é alertado somente quando o processo exibir um padrão não aleatório de variação. Desta forma, ajudando ou substituindo o especialista humano com um algoritmo de reconhecimento de padrões, a

intervenção humana será significativamente reduzida e um sistema inteligente de manufatura é então obtido. Outros processos tem um comportamento semelhante ao sistema de manufatura mencionado acima e podem ser igualmente considerados. A aplicação, descrita no capítulo 6, enfatiza o caráter genérico da metodologia aqui pretendida. Em tal aplicação são usados dados de uma série temporal gerada pela atividade elétrica do cérebro humano (sinal eletrencefalográfico ou EEG) que em última análise se assemelha a um processo de manufatura automatizado.

As técnicas tradicionais de CEP usando Gráficos de Controle tem a sua aplicação fortemente restringida no ambiente descrito acima devido a violação de um preceito estatístico básico que deve ser assumido no emprego do CEP: os dados apresentam uma correlação serial e há com isso dependência nos dados - os dados nesse caso não são IID (independentemente e igualmente distribuídos). Isso ocorre em praticamente todos os processos automatizados que usam dados de sensores ou transdutores em tempo real. A existência dessa correlação serial implica na indicação de muitos alarmes falsos através das cartas de controle. Nesse caso o processo é interrompido freqüentemente para a investigação de um problema quando ele na verdade não existe. O problema então confrontado nessa pesquisa pode ser assim resumido:

*Como implementar de uma forma eficaz o Controle Estatístico de Processos, notadamente uma ótima ferramenta no trato com as variações, em processos serialmente correlacionados sob o regime de tempo real?*

Em recente artigo, Cook e Chiu (1998), abordando apenas um tipo específico de padrões de CEP, descrevem algo que confirma a grande motivação dessa pesquisa e a necessidade de novas metodologias para o problema descrito:

*“Para o melhor do nosso conhecimento, nenhum resultado de pesquisa tem sido publicado até agora, usando redes neurais para controle estatístico de processos para dados serialmente correlacionados”*

### 1.3 Objetivos da Pesquisa

Esse trabalho apresenta um sistema de reconhecimento de padrões baseado em modelamento de séries temporais e no uso de redes neurais artificiais para os dados de uma carta de CEP sob o regime de tempo real. O maior esforço desse trabalho é desenvolver um sistema de reconhecimento de padrões que seja capaz de identificar padrões não aleatórios de variação em uma série temporal assistindo assim na correção de causas assinaláveis que provocam tais variações. O sistema proposto está direcionado primeiramente a processos de manufatura automatizados onde os dados são coletados automaticamente mas existe uma grande gama de aplicações para o sistema proposto, abordando outros tipos de processos. O primeiro interesse desse estudo é controlar a média e a variância de um processo com apenas uma variável característica de qualidade (uma medida característica de qualidade). Com pequenas modificações uma abordagem multivariada pode ser implementada futuramente.

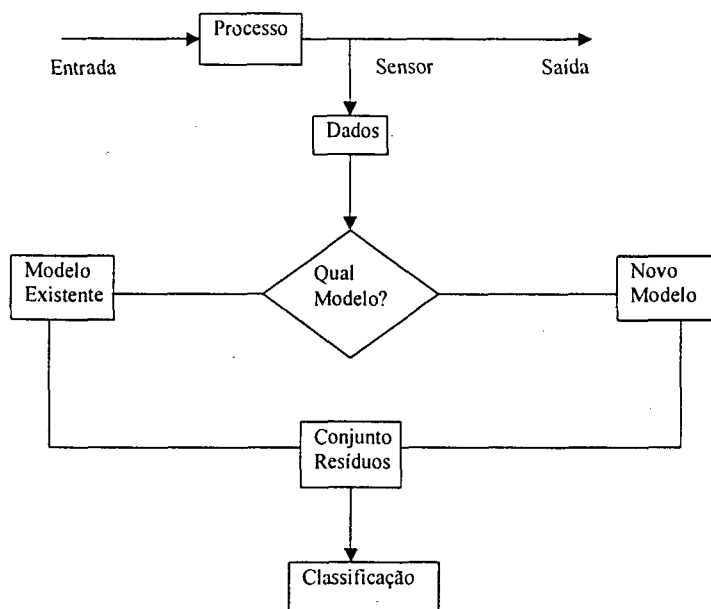
O objetivo principal desse trabalho é desenvolver um sistema computadorizado representado pela figura 1.5, ou seja:

***“Desenvolver uma nova metodologia para a automatização do CEP em regime de tempo real usando modelamento de séries temporais em conjunto com classificação de padrões não aleatórios por meio de redes neurais.”***

Como pode ser visto na figura 1.5, em um determinado tipo de processo automatizado, os sensores captam os dados em tempo real, representando uma característica de qualidade ou item de controle. O sistema deve sinalizar o estado do processo após um certo número de observações serem obtidas pelos sensores. Quanto mais rápido acontecer essa sinalização, tanto melhor. Nesse tipo de aquisição de dados, uma série temporal pode ser facilmente plotada e um fato bem conhecido é que tal série fatalmente apresenta uma correlação serial que impede a aplicação direta das cartas de controle. Devido a essa característica dos processos contínuos os dados não são identicamente e independentemente distribuídos (IID), condição essencial para o

sucesso do monitoramento via CEP. O uso das cartas de controle sob um conjunto de resíduos dos dados originais tem sido sugeridos como a melhor pratica em tais situações [Montgomery,1995].

**Figura 1.5: Metodologia Proposta (Séries Temporais/Redes Neurais/CEP).**



A alternativa aqui apresentada para o uso do CEP em tempo real consiste em um sistema híbrido de controle usando duas partes distintas no tratamento dos dados.

### 1. Geração dos resíduos da série de dados:

Sendo o processo não IID, é necessário uma transformação dos dados segundo um modelamento autoregressivo (AR(1), AR(2), ARMA, etc....) ou mesmo uma forma estacionária. Obtido o modelo é possível calcular os resíduos de uma amostra de dados e, sendo o modelamento satisfatório, os dados serão IID, normalmente distribuídos com média 0 e desvio padrão 1. Para a aquisição desse modelo e consequentemente do conjunto de resíduos, o processo deve estar sob controle. Pode ser então escolhido um modelo para o conjunto de dados de duas formas distintas: (i) Escolhe-se um modelo anteriormente estabelecido - usando principalmente resultados de situações do passado ou (ii) calcula-se um novo modelo com uma nova amostra de dados existentes usando métodos de fácil computação e com pouca (ou nenhuma) intervenção especializada.

## 2. Classificação dos padrões usando redes neurais artificiais:

Os resíduos obtidos em (1) são agora pré-processados e servem de entrada para uma rede neural treinada *off line*. Como resposta, a rede identifica se existe uma situação de falta de controle dando um sinal em caso positivo. No pré-processamento dos dados são utilizadas estatísticas simples como padronização dos dados e subdivisão dos dados em zonas. Toda a operação de classificação, ainda que complexa, pode ser desenvolvida em tempo real pois a fase de treinamento, mais demorada, é desenvolvida *off line*.

Uma aplicação real foi testada usando o sistema acima na tarefa de identificação da atividade patológica do sinal eletrencefalográfico e os resultados foram amplamente satisfatórios. Tal aplicação foi escolhida aproveitando a experiência do doutorando em pesquisas e trabalhos anteriores e teve também o intuito de generalização da metodologia:

Os objetivos secundários mais relevantes do trabalho são sintetizados a seguir:

- Criar um banco de dados dos principais padrões das cartas de CEP para comparações e aperfeiçoamentos posteriores;
- Comparar diversas técnicas de geração de resíduos e de modelamento de séries temporais possíveis em tempo real. Avaliar os resultados em relação às técnicas tradicionais;
- Comparar a performance de algumas redes neurais na tarefa de classificação dos padrões de CEP. Definir as medidas de desempenho das redes.
- Comparar a classificação dos padrões de CEP usando a metodologia desenvolvida em relação as técnicas convencionais;
- Desenvolver uma inteira aplicação para a metodologia;
- Desenvolver um programa computacional que implemente a metodologia.

Como será exposto nas próximas seções os resultados obtidos são estimulantes e mostram o definitivo valor das redes neurais no reconhecimento de padrões das cartas de controle de CEP.

## 1.4 Organização e Metodologia do Trabalho

A metodologia empregada no desenvolvimento do trabalho usa extensivamente o artifício da simulação computadorizada usando principalmente o programa MatLab com suas *Toolboxes* além dos programas Minitab e Statistica, entre outros. O uso de simulação foi escolhido principalmente devido aos seguintes fatores:

- Facilitar a comparação e aperfeiçoamento da metodologia por meio de uma base de dados simulada;
- Lidar com uma ampla gama de situações de CEP, sob o controle do usuário;
- Comparar diversos métodos de implementação;

Em sequência a esta introdução esse trabalho está dividido em 7 capítulos. No capítulo 2 é feita uma revisão da literatura mostrando o que se tem feito e publicado correlatamente a esse trabalho. No capítulo 3 é descrito como o modelamento dos dados foi implementado em tempo real. Uma pequena revisão sobre redes neurais é descrita no capítulo 4. No capítulo 5 é apresentado como a base de dados para o treinamento e teste das redes neurais foi obtida e são descritos os experimentos com as redes neurais e como as medidas de desempenho foram definidas. Uma inteira aplicação é desenvolvida no capítulo 6 abordando o reconhecimento de padrões da atividade eletrencefalográfica. No capítulo 7 são feitas as principais considerações a respeito do desenvolvimento dessa pesquisa, discussões e conclusões. O código do programa em Matlab está representado no final e alguns procedimentos fundamentais são considerados em anexo. Também estão inseridos alguns artigos publicados durante o período desse doutorado que de uma maneira ou de outra, culminaram com a definição e desenvolvimento desse trabalho.

## Capítulo 2 – Revisão da Literatura

---

### 2.1 Introdução

Os modernos métodos de qualidade e confiabilidade tiveram sua origem, conforme cita Keats e Hubele (1989), a partir de um simples memorando datado de 16 de maio de 1924, no qual Walter A. Shewhart propunha as Cartas de Controle para a análise de dados e solução de problemas de qualidade na empresa americana Bell System. Isso introduzia fortemente o conceito de *prevenção* de problemas ao invés de enfatizar a *correção* de problemas. Infelizmente, esse trabalho não recebeu uma grande atenção nos Estados Unidos até a última década. Recentemente, devido a grande competição mundial, o CEP tornou-se uma poderosa ferramenta na garantia da qualidade.

Nesse capítulo serão abordados alguns aspectos do CEP no enfoque dessa pesquisa, revisando o que tem sido feito e publicado nos principais periódicos da área. Para um completo entendimento do CEP, os livros de Grant/Leavenworth(1988), Mittag/Rinne (1993) são uma ótima referência. Primeiramente será abordado a escolha de padrões de CEP sobre os quais a metodologia proposta avaliará seus resultados. Em seguida serão consideradas as peculiaridades do CEP em Tempo Real, abordando Sistemas Automatizados de Manufatura e diversos outros processos que atendem a gama de aplicações no qual a metodologia se destina. Finalmente será avaliado um enfoque da Inteligência Artificial no CEP e o Reconhecimento Neural de Padrões das cartas de controle de CEP.

### 2.2 Padrões em CEP

As primeiras pesquisas em cartas de controle foram destinadas a detecção de deslocamentos nas médias de um processo. Entretanto, podem existir muitos outros padrões em que um processo indica situações onde está fora de controle, como por exemplo, quando apresenta variações sistemáticas, ciclos ou misturas. Quando esses

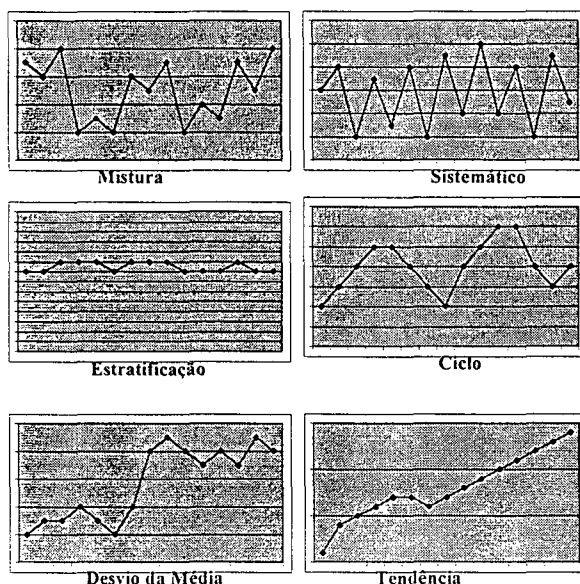


padrões ocorrem, a análise da carta de controle torna-se um problema de reconhecimento de padrão, isto é, deve-se ter um reconhecimento e uma identificação da razão desse comportamento (Montgomery, 1991).

Vários praticantes e pesquisadores tem identificado vários tipos de padrões fora de controle e algumas de suas possíveis causas assinaláveis (Western Electric 1958, Nelson 1985). A figura 2.1 mostra exemplos de tipos de padrões não aleatórios considerados nesse trabalho.

Uma detalhada descrição pode ser obtida no *Statistical Quality Control Handbook* da Western Electric que discute um grande escopo de 15 padrões não aleatórios.

**Figura 2.1: Padrões não aleatórios de CEP.**



Os 6 padrões não aleatórios mais comuns e suas possíveis causas, que abrangem quase todas as possibilidades de problemas de qualidade em processos de manufatura, estudados nessa pesquisa, são resumidos a seguir:

Tendência: Contínuo movimento em uma direção. *Causas:* Fadiga do operador, deterioração de equipamento, desgaste de ferramenta, etc.

Desvios da Média: Abrupta mudança na média de um processo. *Causas:* Alteração do *setup* do processo, mudança ou alteração de matéria prima, mudança ou introdução de novos operadores, mudança nos métodos de inspeção, etc.

Variações Sistemáticas: Um ponto baixo é geralmente seguido de um ponto alto. (Obs.: Uma das características dos padrões aleatórios é que as flutuações de ponto para ponto são não sistemáticas ou não previsíveis). *Causas:* Diferença entre deslocamentos, diferença entre conjuntos de teste e diferença entre linhas de produção onde o produto é amostrado por rotação.

Ciclos: Uma série de altos picos intercalados com uma série de baixos picos. *Causas:* Periódica rotatividade de operadores, mudanças sistemáticas no meio ambiente como temperatura ou fadiga do operador, flutuação de voltagem ou pressão ou alguma variação no equipamento de produção, etc.


Misturas: Os pontos tendem a falhar nas proximidades dos picos com uma ausência de flutuações aleatórias nas proximidades dos valores médios. A mistura é uma combinação de dados de diferentes distribuições. *Causas:* Diferentes fornecedores, máquinas ou equipamentos, supercontrole do processo.

Estratificação: Os pontos estão aglomerados em torno da média do processo. As observações provêm de duas populações com distribuição de probabilidades distintas. *Causas:* Diferentes lotes de materiais misturados na linha, diferença em padrões e equipamentos de medição e/ou pulos e instabilidade frequentes no controle automático.

Para a identificação dos padrões não aleatórios acima o analista do CEP frequentemente usa um conjunto de regras simples sobre os dados (comumente medidas de qualidade) obtidas de um item de controle que se deseja monitorar. A regra mais simples consiste em avaliar se um ponto está além dos limites de controle (usualmente além de 3 desvios padrões). É bem entendido, contudo, que a maior deficiência dessa regra é que somente o último ponto plotado é usado para se tomar a decisão com respeito ao estado do processo. O critério de 3 desvios é geralmente insuficiente para assinalar a existência de distúrbios em um processo e devido a isso vários autores propuseram um conjunto de regras suplementares que são extensivamente aplicadas nas indústrias.

O mais conhecido conjunto de regras foi definido e proposto pela Western Electric que se baseia na divisão de uma carta de controle em 3 zonas sobre as quais os dados são plotados (figura 2.2). Outros conjuntos de regras foram propostos por Grant/Leavenworth e Nelson e estão apresentados nas tabelas 2.1, 2.2 e 2.3.

**Figura 2.2: Representação de zonas em uma carta de controle.**



**Tabela 2.1: Regras Suplementares (Western Electric).**

1	1 ponto além de C.
2	2 de 3 pontos consecutivos em BC ou além.
3	4 de 5 pontos consecutivos em AB ou além.
4	8 pontos consecutivos no mesmo lado da linha central.
5	15 ou mais pontos consecutivos em AA.
6	8 pontos consecutivos sendo que nenhum está em AA.

**Tabela 2.2: Regras Suplementares (Grant/Leavenworth).**

<b>1</b>	7 pontos consecutivos estão do mesmo lado da linha central
<b>2</b>	No mínimo 10 de 11 pontos consecutivos estão do mesmo lado da linha central
<b>3</b>	No mínimo 12 de 14 pontos consecutivos estão do mesmo lado da linha central
<b>4</b>	No mínimo 14 de 17 pontos consecutivos estão do mesmo lado da linha central
<b>5</b>	No mínimo 16 de 20 pontos consecutivos estão do mesmo lado da linha central

**Tabela 2.3: Regras Suplementares (Nelson).**

<b>1</b>	1 ponto além de C
<b>2</b>	9 pontos sequenciais do mesmo lado da linha central
<b>3</b>	6 pontos sequenciais crescentes ou decrescentes
<b>4</b>	14 pontos sequenciais alternando-se crescente e decrescente
<b>5</b>	2 de 3 pontos sequenciais em BC ou além
<b>6</b>	4 de 5 pontos sequenciais em AB ou além
<b>7</b>	15 pontos consecutivos em AA
<b>8</b>	8 pontos sequenciais com nenhum em AA

A maior deficiência dos conjuntos de regras anteriores é que o aumento do erro tipo II (falsa detecção de um problema) é inevitável quando um grande número de regras é introduzido (Roberts, 1958). Além disso, as regras não indicam qual o padrão específico de CEP está ocorrendo, sendo portanto regras gerais. Esses aspectos também foram motivadores para o emprego das redes neurais na tarefa de reconhecimento de padrões, como uma alternativa aos conjuntos de regras suplementares.

### 2.3 CEP em Tempo Real

Em sistemas de manufatura automatizados sensores são frequentemente utilizados para capturar dados em tempo real e deseja-se nesse caso uma resposta da análise também em tempo real. Existem hoje, sofisticadas técnicas de aquisição de dados fornecendo a possibilidade de se obter uma ou mais medidas de diversos itens de controle em praticamente qualquer ponto dos processos de manufatura. Existem

basicamente duas categorias de sistemas de aquisição de dados: distribuídos e centralizados. Nos sistemas distribuídos os sensores são conectados próximos dos processos e placas seriais são usadas para transferir as observações para localizações distantes. Nos sistemas centralizados as medidas são transferidas usando placas paralelas com uma maior taxa de amostragem e geralmente situam-se próximos dos processos ou usam um computador dedicado àquele monitoramento. Em ambos os tipos, podem ainda existir controladores PID (*proportional-integral-differential*), conversores AD (*Analogical-Digital*), placas DSP (*Digital Signal Processing*), capazes de desenvolver uma avalanche de cálculos matemáticos como FFT(*Fast Fourier Transform*), álgebra matricial, *wavelet*,... em tempo real!

Mesmo com esse aumento de automação, a supressão da variabilidade é algo que não deve acontecer, como poucos acreditam. Certamente, haverá um decréscimo nos níveis de variabilidade mas a busca pela maior qualidade sempre vai continuar a existir. Dessa forma, o maior objetivo do CEP em determinar se um processo precisa de ajuste ou não, não é modificado com o aumento nos níveis de automação. Isso porque os padrões de variabilidade continuarão a existir, com maior ou menor grau, pois a variabilidade é inerente a praticamente todos os processos da natureza. As metodologias que lidam com o CEP nesse caso é que sofrerão profundas modificações no sentido de acompanhar o desenvolvimento da automação.

Keats (1989) aponta as principais características para um sistema de CEP em processos de manufatura automatizados como sendo:

- a) Acurácia: Quão perto o modelo usado para controlar um sistema reproduz o sistema controlado;
- b) Velocidade: Quão capaz é o modelo em desempenhar a função em tempo real;
- c) Custo: Quão elevado é o gasto para se conseguir o modelo;
- d) Eficiência: Quão capaz é o modelo em capturar os aspectos críticos do processo;
- e) Adaptabilidade: Quão automático é o modelo no sentido de se adaptar às mudanças do processo.

Nessa abordagem, Keats revela que sempre há um *trade off* entre as características acima. Por exemplo: Se um modelo é bastante complexo tentando capturar todas as nuances do processo, ele pode ter um gasto muito elevado ou pode não ter velocidade suficiente para desempenhar a sua função em tempo real. Tendo alta adaptabilidade, ele pode não ter a acurácia suficiente, etc....

Contreras (1989) sugere também que as seguintes características de análise devem existir em um sistema de CEP para aplicações em tempo real:

- a) Detecção automática de condições fora de controle: Técnicas de reconhecimento de padrões devem detectar quando um sistema está saindo de controle;
- b) Análise Multidimensional: Múltiplas características de um item de controle devem ser investigadas ao mesmo tempo quando necessário;
- c) Análise de múltiplos sinais: Múltiplos itens de controle devem ser investigados ao mesmo tempo;
- d) Análise Multivariada: Se os itens de controle ou as suas características são interdependentes, uma análise multivariada torna-se necessária;
- e) Análise de Dados Autocorrelacionados: A suposição de independência das observações é frequentemente violada nos casos em que os dados são obtidos em tempo real. Várias novas técnicas podem ser usadas para o tratamento dessa questão.

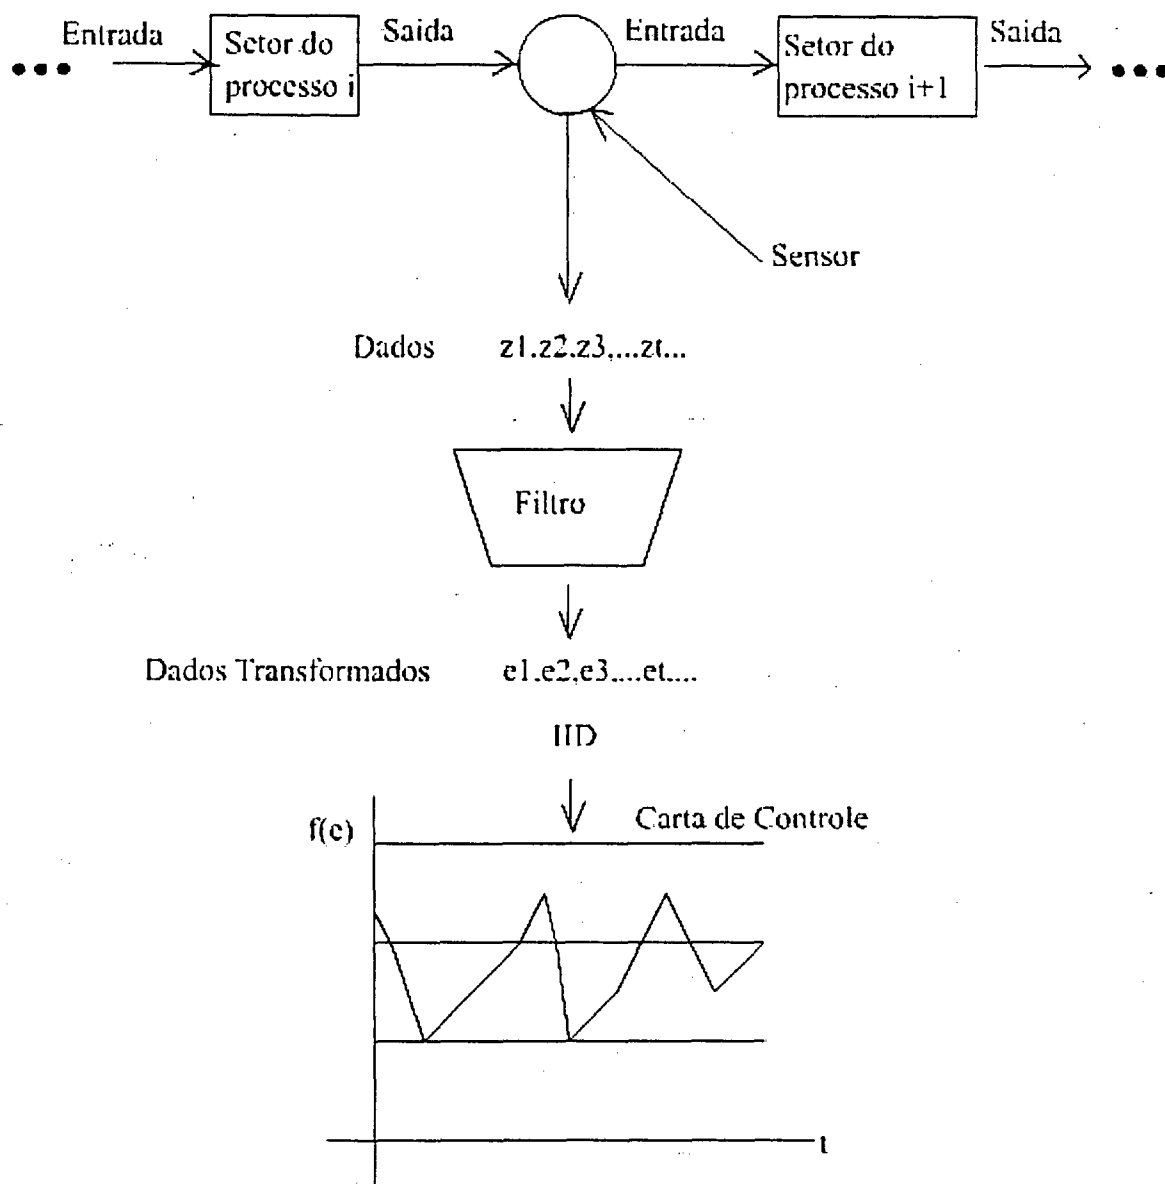
No desenvolvimento de um modelo que atenda aos requisitos acima, o item (a) torna-se uma condição essencial para as novas metodologias e que notadamente as regras clássicas necessitam ser atualizadas para a sua implementação. Os testes de sequência (*runs rules* ou *runs tests*), tornam-se aqui inviáveis pois além da dependência do especialista, não atendem a suposição de independência dos dados. O uso dos pacotes computacionais existentes no mercado, que desempenham com grande velocidade os testes de sequência, não são flexíveis a ponto de poderem ser incorporados módulos de aquisição de dados e rotinas que desempenhem os outros itens. Tais programas tem na verdade pouca adaptabilidade aos processos reais e prestam-se mais a trabalhos acadêmicos. Os itens (b), (c) e (d) são na verdade um aprimoramento do caso univariado ao invés de uma nova metodologia.

A maior atenção deve ser dada ao item (e) pois a violação dessa propriedade inviabiliza a aplicação das cartas de controle em praticamente todos os processos em ambientes automatizados. Nesse tipo de ambiente, as observações podem exibir uma correlação serial que inviabiliza o uso das cartas de controle de Shewhart. Os dados nesse caso violam uma propriedade básica das cartas de controle que consiste na independência dos dados. É conhecido que o uso das cartas  $\bar{X}$ , R e Médias Móveis produzem um elevado número de falsos alarmes aumentando em muito o chamado erro Tipo II, quando empregadas nesse ambiente.

Vários autores tem recomendado o uso de modelamento por séries temporais quando existe a presença de dados serialmente correlacionados. Desenvolvido tal modelo, o controle estatístico de processos pode então ser aplicado ao conjunto de resíduos gerados. Montgomery e Friedman (1989) apresentam as principais idéias abordando três tipos particulares de cartas de controle: Shewhart para pontos individuais, CUSUM e GMA, tanto para processo univariado como para multivariado. Berthouex (1978) ilustram como esse procedimento geral pode ser aplicado no tratamento dos resíduos de plantas. Também relacionados estão os trabalhos de Notohardjono e Fermer (1986), Liao (1982) e Samohyl (1998).

O gráfico da figura 2.3 mostra um sistema de CEP para um ambiente de manufatura automatizado (Montgomery/Friedman, 1989). Nesse caso, o tamanho da amostra para as cartas de controle é normalmente unitário, levando certamente a problemas de correlação serial e contrastando com a suposição dos subgrupos racionais das cartas de controle que efetuam as medidas tipicamente com observações periódicas e com tamanho de amostras maior que 1. Gerando um conjunto de resíduos a partir de um modelamento estocástico (tipicamente autoregressivo), tal conjunto de resíduos será IID se o processo estiver sobre controle e então uma carta de controle poderia ser aqui empregada. Mudanças no nível de dispersão dos dados originais poderiam ser então capturadas pelas cartas de controle agindo sobre o conjunto de resíduos.

Figura 2.3: Sistema de CEP para um ambiente de manufatura automatizado.



O modelo Autoregressivo Integrado de Médias Móveis (ARIMA) pode ser considerado como ideal para o desenvolvimento de um modelo estocástico da série temporal dos dados originais. Esse modelo pode acomodar não somente estruturas autocorrelacionadas como também comportamento não estacionário, tendências, misturas, etc.... Alwan e Roberts (1989), abordando o uso de modelos de séries temporais e cartas de controle em um conjunto de dados proposto por Box e Jenkins



(1970) sugerem também que os modelos ARIMA(0,1,1) podem servir como boas aproximações em muitas ou quase todas as aplicações.

Miller/Walker(1988) listam um conjunto de processos de manufatura que usam os recursos do CEP e poderiam ser beneficiados com esse tipo de metodologia:

- |                    |                            |
|--------------------|----------------------------|
| • Filtragem        | • Tratamento de calor      |
| • Extração         | • <i>Welding</i>           |
| • Fermentação      | • <i>Casting</i>           |
| • Destilação       | • <i>Forging</i>           |
| • Refinamento      | • <i>Extrusion</i>         |
| • Reação           | • <i>Injection Molding</i> |
| • <i>Pressing</i>  | • <i>Spraying</i>          |
| • Cortes de metais | • <i>Soldering</i>         |

Finalmente, é importante enfatizar que não só os sistemas automatizados de manufatura atendem ao regime de tempo real aqui descrito tendo como requisitos um grande volume de informações em pouco espaço de tempo. Existe um grande escopo de aplicações para esse tipo de metodologia. Algumas dessas possíveis aplicações são:

- Processos químicos industriais como
  - *Annealing*;
  - *Sintering*;
  - Transporte;
- Processos metalúrgicos;
- Processos diversos que envolvam Reconhecimento de Padrões em sinais de séries temporais na área médica como:
  - Sinais EEG (produzidos a partir do cérebro)
  - Sinais ECG (produzidos a partir do coração)
  - Sinais EOG (produzidos a partir do oculograma)
  - Sinais de Potenciais Evocados

2.3 Inteligência Artificial e CEP

A metodologia aqui proposta faz uso extensivo de redes neurais artificiais. A Inteligência Artificial (IA) tem sido definida como “um campo de estudo que procura explicar e simular o comportamento inteligente em termos de processos computacionais” (Schalkoff, 1990 ) ou ainda como “um ramo da ciência da computação que se preocupa com a automação do comportamento inteligente”(Luger&Stubbefield, 1993). Nesse sentido, a IA é categorizada como um sistema que atua racionalmente e é vista como o estudo e construção de agentes racionais.

Um agente é algo que pode perceber seu meio ambiente através de sensores e atuar sobre esse ambiente através de alguns mecanismos. Um agente racional é um agente que toma a ação correta (Russel&Norvig, 1995). Uma medida de desempenho é o critério que determina o quão bom é o agente racional e a tarefa da IA é projetar um programa agente que implemente um mapeamento entre a percepção do meio ambiente e uma referida ação. Esse programa irá rodar em algum tipo de arquitetura e o relacionamento entre agente, arquitetura e programa pode ser sintetizado pela seguinte expressão:

Agente = Arquitetura + Programa

Relacionado com o CEP em tempo real um agente racional pode ser descrito em termos de IA de acordo com a tabela 2.4.

Tabela 2.4: Um Agente e sua descrição em termos de IA.

<b>Tipo de Agente</b>	Sistema de reconhecimento de padrões não aleatórios em gráficos de CEP.
<b>Percepção</b>	Medidas de um item de controle obtidas em tempo real por meio de sensores.
<b>Ação</b>	Sugerir causas de possíveis problemas de produção a um operador, atuar no processo interrompendo a produção, acionar controladores, sinalizar, etc.
<b>Objetivo</b>	Reconhecer determinados tipos de padrões em séries temporais e suas possíveis causas.
<b>Ambiente</b>	Sistemas de manufatura automatizados

O ambiente no qual este agente está definido possui as propriedades descritas pela tabela 2.5.

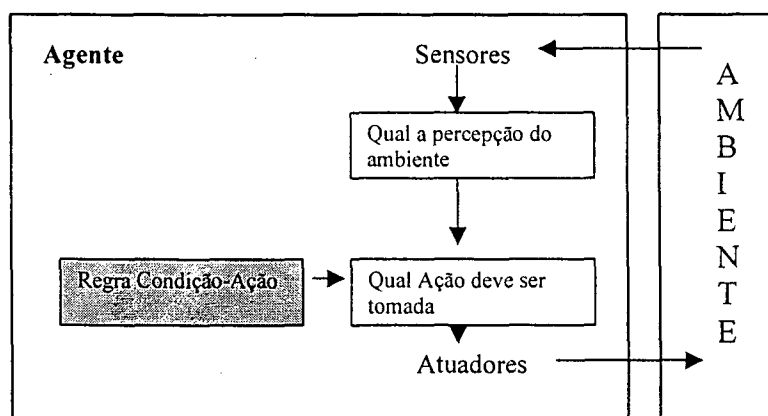
**Tabela 2.5: As Propriedades do Ambiente do Agente.**

<b>Acessível</b>	Os sensores detectam todos os aspectos que são relevantes para a escolha da ação a ser tomada.
<b>Determinístico</b>	O próximo estágio do ambiente é completamente determinado pelo estado atual e ações selecionadas pelo agente
<b>Episódico</b>	Cada episódio consiste da percepção e ação de um agente
<b>Semi-Dinâmico</b>	O ambiente não muda com o passar do tempo mas o desempenho do agente sofre alterações
<b>Discreto</b>	Existe um número limitado de percepções e ações a ser tomadas pelo agente

Em termos de IA, o programa agente a ser implementado é do tipo *reflexo simples* que usa conexões do tipo *regra if-then* ou *regra condição-ação* e está representado na figura 2.4.

Uma das mais importantes técnicas para a percepção do ambiente consiste hoje nas Redes Neurais e a ação a ser tomada pode ser efetuada a partir de um Sistema Especialista avaliando a *regra condição-ação*. Temos assim nesse caso um agente usando um programa híbrido.


**Figura 2.4: Agente do tipo Reflexo Simples.**



No contexto do CEP os seguintes passos exemplificam a atuação do agente da figura 2.4.

1. Um conjunto de medições são obtidas a partir de um sensor em um processo de manufatura qualquer;
2. Uma rede neural previamente treinada identifica um padrão não aleatório do tipo tendência, nos moldes da figura 2.5;

**Figura 2.5: Exemplo de tendência de uma carta de controle de um processo.**



3. Um Sistema Especialista identifica a partir de um conhecimento prévio que a tendência detectada anteriormente está relacionada com a deterioração da matéria-prima;
4. Um sistema de alarme indica que a matéria prima deve ser averiguada.

Dooley, K. (1986) descrevem que o CEP pode ser pensado como consistindo de vários estágios (*observação, avaliação, diagnóstico, decisão e implementação*) os quais ele define como Janelas de Qualidade. Assim, o processo é *observado* através dos dados do produto e então a estabilidade do processo é *avaliada* por meio dos padrões não aleatórios das cartas de controle. Um padrão não aleatório implica em um *diagnóstico* de uma possível causa para o comportamento não aleatório e uma vez identificada a causa, uma *decisão* deve ser tomada no sentido de uma ação corretiva que é então *implementada*.

O restante desse trabalho se ocupará principalmente com o estudo da fase de *avaliação* deixando as outras fases para posteriores estudos, tendo em vista a grande necessidade gerencial que se deve ter nessas fases. A fase de avaliação, mais científica,


requer um estudo mais detalhado e a proposição de metodologias inovadoras. As outras fases, já bem sedimentadas são de mais fácil implementação.

## 2.5 Reconhecimento de Padrões em CEP

O reconhecimento de padrões tem sido frequentemente dividido como Estatístico, Sintático ou Neural. Contudo, com o advento tecnológico e a existência de sistemas híbridos, a distinção entre os três tipos tem sido tênue. A maior verdade nesse caso é que o reconhecimento de padrões *computadorizado* pode estabelecer relações entre observações e algumas informações úteis que podem automatizar um processo com pouca ou nenhuma informação.

Pao (1989), descreve genericamente que o procedimento para o reconhecimento de padrões pode ser sumarizado como mostra a figura 2.6. Na fase de Extração de Características são decididas quais as peculiaridades  $x$  do objeto  $X$  devem ser descritas simbolicamente ou numericamente na forma  $f(x)$ . Na fase de Aprendizagem é usado um conjunto de treinamento para inferir regras de decisão ou o mapeamento  $M(\cdot)$ . Na fase de Classificação usa-se a função  $M(f(x))$  para conduzir a uma classificação  $c(x)$ .

**Figura 2.6: Representação dos passos em um Reconhecimento de Padrões.**



Nas técnicas tradicionais de reconhecimento de padrões Estatístico a classificação é feita particionando o *Espaço de Características* em regiões mutualmente exclusivas com cada região correspondendo a uma classe de padrões. Essa aproximação

é apropriada para aplicações onde os padrões podem ser efetivamente representados na forma vetorial e informações explícitas sobre os padrões não são consideradas importantes (Fu, 1982). As vezes também o nível de computação exigido torna-se razoavelmente complexo que nos últimos anos, tal aproximação tem sido preterida ao reconhecimento neural de padrões. Na abordagem sintática, são enfatizados descrições *estruturais* de padrões usando uma analogia entre a estrutura de padrões e a sintaxe de uma *linguagem*. Na prática, a aproximação sintática tem tido limitado sucesso no tratamento com problemas gerais de reconhecimento de estruturas de padrões (Pao, 1989). A última abordagem, o reconhecimento de padrões neural será utilizado nessa pesquisa e será melhor detalhado nos próximos capítulos.

O reconhecimento de padrões pode ser considerado uma forma alternativa de usar as cartas de CEP em tempo real. A literatura sobre isso não é tão vasta e alguns trabalhos foram investigados e norteiam fortemente os rumos dessa pesquisa. Tais trabalhos apresentam, contudo, algumas limitações que são aqui listadas (muitas vezes indicadas pelos próprios autores).

Swift (1987) desenvolveu um sistema de reconhecimento de padrões sob a forma de uma árvore de decisão usando uma série de testes de hipóteses para identificar seis padrões não aleatórios do gráfico Xbarra. O algoritmo não pode ser precisamente classificado em nenhuma das abordagens citadas acima e usa muita heurística na sua aproximação. O algoritmo usa técnicas como autocorrelação, cartas CUSUM, análise de regressão e regras suplementares. As principais limitações do trabalho são:

- (a) O algoritmo não é flexível. Seria muito difícil incorporar novas regras heurísticas para novos padrões;
- (b) A taxa de falsos alarmes é muito acentuada devido ao uso da série de testes de hipóteses;
- (c) A capacidade do reconhecimento de padrões é totalmente determinada pela sequência dos testes de hipóteses;
- (d) A acurácia do algoritmo é grandemente influenciada pela forma como as regras da *Western Electric* são aplicadas.

Cheng (1989) desenvolveu um sistema baseado no reconhecimento sintático de padrões que demonstrou grande capacidade de reconhecimento de padrões na carta Xbar. Algumas limitações podem ser aqui consideradas:

- (a) A capacidade de reconhecimento de alguns padrões torna-se muito dependente de como o padrão é apresentado ao algoritmo. Por exemplo: Um ciclo será identificado se o vetor contendo o ciclo estiver no início da fase. Há um problema de invariância dos dados que deve ser superado.
- (b) O processo de *template-matching* usado é de certa forma lento e pode comprometer as aplicações em tempo real.

Alguns pesquisadores tem investigado o uso de redes neurais para dados IID. O Reconhecimento Neural de Padrões aqui desenvolvidos utilizam padrões das cartas de controle para processos na maioria simulados com pouco (ou nenhum) tratamento para o problema da autocorrelação. Tais trabalhos são sucintamente descritos a seguir.

Hwarng (1992) desenvolveu uma metodologia para o reconhecimento de padrões em cartas X-bar usando *backpropagation* e *Boltsman Machine*. Muitas idéias originais surgiram com esse trabalho como a incorporação de diversos índices de desempenho e a metodologia de construção de um banco de dados para futuros investigadores. Algumas considerações, contudo podem ser aqui consideradas.

- (a) O algoritmo não trata pontos fora de controle;
- (b) A incorporação de novos padrões torna-se muito complicada;
- (c) O problema da invariância, como no trabalho de Cheng (1989), não é tratado;
- (d) A sua aplicação prática é muito restrita pois a suposição de autocorrelação dos dados não é tratada;

- (e) A técnica de pré-processamento é falha no sentido de lidar com situações reais (o próprio autor sugere a inserção de lógica difusa para melhorar esse ponto);

Guo & Dooley (1992) por meio de um interessante algoritmo de simulação propõem um método de identificação de mudança de estrutura em gráficos de CEP. O sistema utiliza os ajustes de um modelo autoregressivo e de estatísticas dedicadas para monitorar o desvio da média de um processo. Tal algoritmo apresenta alguns pontos que devem ser destacados:

- (a) Identifica apenas um tipo de padrão;
- (b) A entrada da rede neural *backpropagation* usa um grande número de estatísticas de pré-processamento para a abordagem de apenas um tipo de padrão.

Lucy-Bouler (1991) apresenta um interessante sistema especialista para o reconhecimento de padrões em CEP que usa autocorrelação, cartas CUSUM e *runs rules*. Algumas considerações a esse trabalho são:

- (a) O algoritmo só se aplica a dados não correlacionados;
- (b) Não trata padrões com pontos fora de controle;
- (c) Não permite a inclusão de novos padrões

Tontini (1995) usa um sistema híbrido com a rede RBF-Fuzzy-ARTMAP para a identificação de vários tipos de padrões de CEP, criando uma inovadora metodologia para o tratamento de situações em tempo real. Aqui as considerações são:

- (a) Não trata o problema da invariância de padrões no tempo;
- (b) Não disponibiliza um claro algoritmo de simulação;
- (c) Não investiga o pré- processamento;
- (d) Não aborda a ordem de apresentação dos padrões para a rede neural;



Em termos de CEP para dados correlacionados, contudo, poucos resultados de pesquisa tem sido ou foram publicados. Cook e Chiu (1998) desenvolvem um estudo comparativo usando uma metodologia similar a descrita neste texto, para somente detecção do desvio da média usando modelos AR(1) e AR(2) em conjunto com redes neurais de função de base radial. Os resultados mostraram-se superiores ao uso de técnicas convencionais mas o uso da metodologia apresenta uma dependência do especialista em modelamento de séries temporais para o cálculo dos resíduos, dificultando em muito a sua aplicação em tempo real.

## **Capítulo 3 – Modelamento de Dados em Tempo Real**

---

### **3.1 Introdução**

Modelos de séries temporais podem ser usados para a filtragem de sinais autocorrelacionados em processos sob o regime de tempo real. Os resíduos gerados dessa filtragem, agora *iid*, podem ser usados no controle estatístico de processos.

Tratando-se de séries temporais, a teoria de autocorrelação torna-se um instrumento fundamental de discussão e obviamente, para diferentes processos, a estrutura de autocorrelação é diferente. Enquanto alguns processos podem ser modelados como autoregressivos AR(1), AR(2), etc..., outros podem ser modelados como médias móveis ou ainda muitos outros modelos. Em casos não estacionários, um certo processo pode ser remodelado de uma forma totalmente diferente do que foi modelado em determinado estágio anterior.

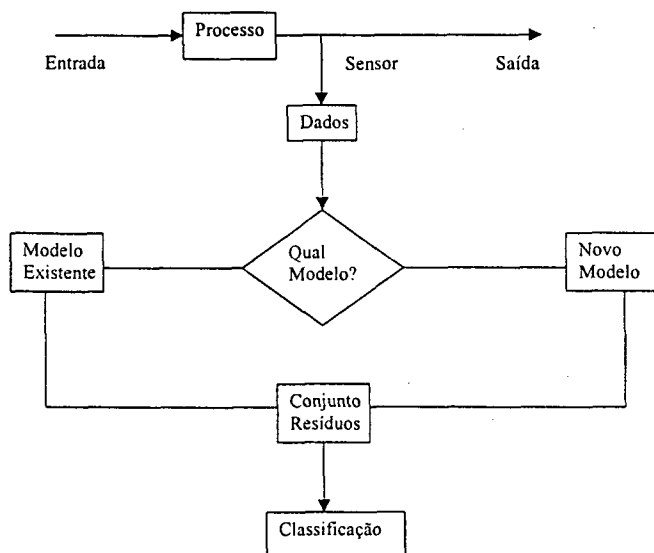
A metodologia aqui proposta consiste em usar um método automático (ou com pouca intervenção humana) no sentido de escolher um modelo que represente consistentemente a estrutura de autocorrelação do processo. Depois da escolha do modelo, pode-se facilmente obter o conjunto de resíduos para a investigação dos padrões por meio do CEP. De uma forma geral, o modelamento de séries temporais tem exigido quase sempre a presença de um especialista e também de programas dedicados onde um conjunto de testes de hipóteses é avaliado para a escolha final do modelo. Isso inviabiliza o grande escopo de aplicações em tempo real devido ao caráter dinâmico da obtenção dos dados.

Um ponto importante a ressaltar aqui é que o processo precisa estar sob controle quando na definição do novo modelo a ser estimado. Alguns autores consideram isso uma condição limitante dos processos automatizados mas que foi aqui usada pelas seguintes razões. Primeiramente, o uso da experiência do profissional que atua no monitoramento não deve ser totalmente negligenciada e pode ser aproveitada na

definição do estado do processo. Isso não é tão complicado pois esse profissional não fica envolvido com cálculos matemáticos nem necessita de grandes conhecimentos para dizer se um item de controle está ou não se comportando adequadamente por um certo período de tempo. É bom lembrar que essa dependência acontece somente em uma parte inicial da implementação da metodologia. Uma outra razão é que isso simplifica em muito a utilização do trabalho a ser feito na fase de classificação. A não adoção dessa condição de controle implica na utilização de redes neurais não supervisionadas na pesquisa do conhecimento do especialista e isso torna o metodologia complexa com menor possibilidade de aplicação prática. Futuras investigações, contudo, poderão ser feitas nessa direção.

Em termos práticos a estimação do modelo e geração dos resíduos consiste em apenas uma só fase. Quando os dados são gerados, nos moldes da figura 1.5, abaixo reproduzida, o especialista é levado a “ajudar” a escolher um modelo existente ou, em caso de um novo processo, indicar que nem um dos modelos existentes se aplica ao caso e que um novo modelo deva ser gerado. Nesse caso ele só precisa identificar que o processo está sob controle para a estimação de um novo modelo. Uma vez escolhido um novo modelo ele será armazenado como representativo do processo e a futura escolha será automática, sem a presença desse especialista.

**Figura 1.5 (Reprodução): Geração do conjunto de resíduos para o uso do CEP.**



Esse capítulo tem como finalidade descrever os procedimentos aqui adotados para a obtenção dos resíduos em tempo real. Na seção 3.2 o caso univariado será apresentado abordando a implementação das metodologias padrões e considerando diversas novas alternativas desenvolvidas recentemente. Na seção 3.3, o algoritmo implementado será comparado com resultados já sedimentados na literatura e sua aplicabilidade no restante do trabalho.

### 3.2 Modelos Univariados

Os dados originais de um processo univariado representados por uma série temporal  $Z_1, Z_2, \dots, Z_t, \dots$ , os quais podem exibir um comportamento serialmente correlacionado devem ser transformados em um conjunto de resíduos  $e_1, e_2, e_3, \dots, e_t, \dots$  e sobre esses resíduos é feita a análise de uma carta de controle. O modelo ARMA (*Autoregressive Moving Average*) será aqui utilizado para representar a série temporal dos dados originais pois pode acomodar não somente estrutura de dados correlacionados mas também comportamento não estacionário, tendências, além de outros tipos de padrões.

A forma geral do modelo ARMA( $p, q$ ) está representado na equação abaixo:

$$Z_t = \xi + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad 3.1$$

onde  $\phi_1, \phi_2, \dots, \phi_p$  são os parâmetros autoregressivos,  $\theta_1, \theta_2, \dots, \theta_q$  são os parâmetros das médias móveis e  $\xi$  é o parâmetro relacionado ao nível da média da série. Se os dados originais exibem não estacionaridade em seu comportamento, então a série  $Z_t$  pode ser diferenciada tendo-se nesse caso um modelo ARIMA( $d, p, q$ ) onde  $d$  representa o número de diferenças para tornar a série estacionária. Podemos assim rescrever a equação anterior da seguinte forma (Montgomery, 1985):

$$\hat{\Phi}_p(B) \tilde{Z}_t = \varepsilon_t \Theta_q(B) \quad 3.2$$

Onde  $\hat{\Phi}_p(B) = (1 - \sum_{j=1}^p \phi_j B^j)$ ,  $\Theta_q(B) = (1 - \sum_{j=1}^q \theta_j B^j)$ .  $B$  é operador de diferença  $B^j Z_t = Z_{t-j}$  e  $\tilde{Z} = Z_t - \bar{Z}$ . Métodos de mínimos quadrados não lineares podem ser empregados para estimar os parâmetros  $\phi_j$  e  $\theta_j$ .

Sendo  $\hat{\Phi}_p(B)$  e  $\Theta_q(B)$  representativos dos polinômios autoregressivos e de médias móveis respectivamente, com os parâmetros  $\phi_j$  e  $\theta_j$  substituídos por suas estimativas, então o conjunto de resíduos pode ser representado por

$$e_t = \hat{\Theta}_q^{-1}(B) \hat{\Phi}_p(B) \tilde{Z}_t \quad 3.3$$

Sendo a forma do modelo da equação 3.2 correta e o processo estando sobre controle, então os resíduos da equação 3.3 não são correlacionados.

Para ilustrar esse procedimento, suponha a série representada pela figura 3.1 na qual uma característica de qualidade é avaliada em tempo real. As primeiras 50 observações são tomadas durante um período de tempo quando o processo é pensado estar sobre controle estatístico. Baseado nessas observações, o modelo estocástico do processo pode ser dado pela equação 3.4, calculado de uma forma automática:

$$Z_t = 50 + 0.8Z_{t-1} - 0.3Z_{t-2} + \varepsilon_t \quad 3.4$$

A segunda metade da figura 3.1 plota as próximas 50 observações tomadas do processo e a figura 3.2 mostra o conjunto de resíduos sobre os quais o controle estatístico de processos deve atuar. Existe uma nítida impressão visual da existência de um deslocamento da média do processo e o uso de técnicas de reconhecimento de padrões podem capturar mais rapidamente e automaticamente esse comportamento. Tais técnicas serão empregadas no próximo capítulo

Figura 3.1: Série representando um processo em tempo real  
Montgomery/Friedman(1986).





Figura 3.2: Série de resíduos correspondente a figura 3.1 usando o modelo da  
equação 3.4.



O procedimento típico adotado para a construção do modelo estocástico de uma série temporal univariada consiste principalmente nos seguintes passos:

(1) Identificação

Onde são identificadas a necessidade de diferenciar os dados para tornar a série estacionária e calculados a ordem do processo autoregressivo ( $p$ ) e do processo de médias móveis ( $q$ ). Tradicionalmente, as principais ferramentas nessa fase são as funções de autocorrelação e autocorrelações parciais.

(2) Estimação

Onde são estimados os coeficientes AR e MA e feito o diagnóstico a partir dos resíduos estimados. Aqui podem ser utilizados métodos de estimação como mínimos quadrados.

(3) Previsão

Onde são feitas as previsões a partir do modelo estimado. São usados resultados conhecidos para a avaliação da previsão.

Em termos de previsão, suponha por exemplo que se tenha uma série com 100 observações. Usa-se nesse caso, por exemplo, as primeiras 75 observações para a estimação do modelo e as restantes observações para a previsão. Em processos automatizados onde se tem a necessidade de se estimar um grande número de séries temporais em um pequeno intervalo de tempo, a etapa de previsão passa a ter um caráter secundário em detrimento da geração dos resíduos em tempo real. Nesse trabalho, a tarefa de previsão é feita somente como medida de *performance* da metodologia quando confrontada com resultados já sedimentados de séries temporais clássicas. Na implementação final do algoritmo, contudo, a previsão tem importância secundária.

Alguns recursos computacionais são fundamentais na construção de um sistema automático para o modelamento de séries temporais. Esses procedimentos podem ser programados interativamente no sentido de fornecer o modelo final da série temporal. Nesse trabalho, a avaliação da necessidade de diferenciação da série fica a critério do

usuário na análise inicial do estado do processo. Desenvolvimentos futuros deverão ser feitos nesse sentido com o intuito de completamente automatizar a metodologia. Tais procedimentos foram desenvolvidos no sentido de automatizar todo o processo de geração do conjunto de resíduos em tempo real e são listados a seguir ( uma revisão sobre tais procedimentos e conceitos encontra-se em (Brockwell,1991):

- Critérios de seleção da ordem do modelo adotados (os respectivos nomes são encontrados no programa computacional, conforme anexo C):
  - ARORDER - Estima a ordem do modelo AR usando correlação e cumulantes;
  - MAORDER - Estima a ordem do modelo MA usando cumulantes;
- Outros critérios de seleção da ordem do modelo também considerados:
  - FPE - *Final Prediction Error*;
  - AIC - *Akaike Information Criterion*;
  - BIC - *Bayesian Akaike Information Criterion*;
  - CAT - *Parzen's CAT Criterion*;
  - MDL - *Minimal Description Length Criterion*;
  - SBC - *Schwartz's Bayesian Criterion*;
  - PHI - Critério Phi;
- Métodos de Estimação do modelo autoregressivo adotados:
  - ARMAQS - Estima os parâmetros ARMA por meio do algoritmo *q-slice*;
  - ARMARTS - Estima os parâmetros ARMA por meio do algoritmo de resíduos de séries temporais;
- Outros métodos de estimação do modelo autoregressivo também considerados:
  - Earpyw - Yule-Walker (com algoritmo de Levinson-Durban);
  - Earpk - Filtros de Kalman;
  - Earplms - Método LMS;
  - ARRCES - Estima os parâmetros AR usando correlação e cumulantes;
  - MAES - Estima os parâmetros MA usando correlação e cumulantes;



- Procedimentos complementares
  - acovf - Função de autocovariância;
  - acf - Função de autocorrelação;
  - pacf - Função de autocorrelação parcial ACF;
  - acf2pacf - Converte acf para pacf;
  - biacovf - Função biautocovariância (cumulante de terceira ordem);
  - yuwa - Resolve a equação de Yule-Walker (converte acovf em parâmetros AR);
  - eigval - Calcula autovalores da matriz de autocovariância.


### 3.3 - Análise de Resultados

O algoritmo aqui desenvolvido foi comparado com resultados clássicos da literatura. Foram investigadas algumas séries temporais com várias ordens dos parâmetros  $p$  e  $q$  bem como diferentes valores dos coeficientes AR e MA. Foram testados os diversos procedimentos acima considerando a exatidão dos resultados em relação a algumas séries clássicas. Os critérios de seleção da ordem do modelo ARORDER e MAORDER, e os métodos de estimação do modelo autoregressivo, ARMAQS e ARMARTS foram adotados principalmente devido a sua simplicidade de computação, uma vez que todos os procedimentos alternativos mostraram resultados satisfatórios. Alguns resultados são apresentados a seguir.

*Comparação com a série de temperaturas descrita em Box/Luceño (1998)*

Tal série consiste de 80 medidas de temperatura obtidas por sensores na saída de um processo industrial.


**Figura 3.3: Série de temperaturas.**



Os seguintes clássicos resultados descritos em Box/Luceño(1998) e aqui também comprovados procuram validar a metodologia aqui empregada:


1) A função de autocorrelação (ACF), mostrada na figura abaixo apresenta um decréscimo gradual (mais do que uma quebra abrupta) e inicialmente tal decréscimo é aparentemente exponencial, sugerindo que um comportamento autoregressivo deveria ser tentado.

**Figura 3.4: Função ACF.**




2) A função de autocorrelação parcial (PACF) sugere que um modelo autoregressivo de ordem 1 ou maior poderia representar a série.

Figura 3.5: Função PACF.




- 3) A figura seguinte mostra a plotagem dos resíduos calculados com os procedimentos ARORDER, MAORDER, ARMAQS e ARMARTS que definiram exatamente o modelo  $z_t = 0.69 z_{t-1} + a_t$

Figura 3.6: Resíduos da série de temperaturas




- 4) A função ACF dos resíduos  $a_t$  é mostrada na figura seguinte e indica uma razoável adequação do modelo.

Figura 3.7: Função ACF dos resíduos




- 5) A figura seguinte mostra a plotagem dos resíduos a partir de um modelo  $AR(2)$ .

Figura 3.8: Resíduos de um modelo  $AR(2)$ .



- 6) A função ACF para o modelo  $AR(2)$  não mostra nenhum ganho significativo em relação ao modelo  $AR(1)$ .

Figura 3.9: Função ACF para  $AR(2)$ .



A partir dos gráficos acima e de sua análise básica envolvendo alguns conceitos de séries temporais pode-se concluir que o modelo AR(1) proposto representa confiavelmente a série de dados.

O algoritmo aqui proposto para a obtenção dos modelos em tempo real encontrou exatamente os mesmos resultados. Primeiro foi determinado a ordem do modelo e depois foram calculados os seus parâmetros. O programa, em Matlab, está representado no anexo C. Da mesma forma foram analisadas as séries de filmes metálicos (Box/Luceño, 1998) e de diâmetros (Montgomery/Friedman, 1986), encontrando-se os mesmos resultados clássicos definidos pelos autores.

Finalmente, a seguinte observação deve ser considerada quando na geração dos resíduos em tempo real: Séries temporais que podem ser representadas por modelos de médias móveis MA são raros em tempo real (Box/Luceño, 1998). Entretanto, um fenômeno denominado *carry-over* pode produzir uma série caracterizada pelo modelo MA(1). Tal fenômeno é algumas vezes evidente em processos onde uma quantidade aleatória de produtos remanescentes é considerada nas próximas medidas, como nos casos de bateladas (*batch process*).

## **Capítulo 4 – Redes Neurais Artificiais**

---

### **4.1- Introdução**

Esse capítulo descreve uma breve revisão sobre redes neurais artificiais. A seção 4.2 apresenta o conceito de redes neurais artificiais e na seção 4.3 o modelo de neurônio artificial é também sumamente descrito. Nas seções 4.4 e 4.5 são tecidas considerações a respeito do aprendizado, da topologia e da classificação de padrões das redes neurais, respectivamente. A seção 4.6 relata o uso de redes neurais para a classificação de padrões. Uma revisão da literatura é descrita na seção 4.7.

### **4.2 - O que são as redes neurais artificiais**

Uma rede neural artificial é um sistema massivamente paralelo composto de elementos ou unidades altamente interconectados (também chamados de neurônios) e processamento interativo que são baseados em modelos neurobiológicos (Dayhoff,1990).

A maior tarefa de uma rede neural é aprender e manter um determinado modelo suficientemente consistente para alcançar os objetivos de uma aplicação de interesse (Haykin,1994). Esse sistema atua como um estimador de função não linear e não paramétrico que aprende a mapear entradas em saídas segundo uma superfície não-linear e multidimensional adequando-se a funções não lineares e multivariadas (Zurada,1992).

Desde que as redes neurais tentam simular certos aspectos do sistema nervoso humano, elas exibem muitas propriedades para resolver problemas complexos. As seguintes características das redes neurais enfatizam o seu poder em termos de reconhecimento de padrões, fazendo-as particularmente atrativas para o problema de classificação de padrões não aleatórios de um gráfico de CEP:

- Podem aprender de exemplos e adaptar-se a novas situações;
- São robustas (podem abstrair informações de dados com ruído, incompletos ou não precisos);
- Podem generalizar a partir de exemplos (podem prover soluções corretas para dados similares, não vistos no treinamento)
- Podem construir soluções rapidamente sem muito domínio do conhecimento do processo;
- Podem aproximar qualquer função multivariada complexa (mal definida ou desconhecida) e formar uma decisão de classificação a partir do reconhecimento de padrões discriminantes;
- São computacionalmente eficientes (tem a velocidade para operar em tempo real).

Os dois pontos positivos mais importantes relacionados com as redes neurais são que elas podem aprender com a experiência e podem generalizar a partir de exemplos (Haykin, 1994). A elas também geralmente estão relacionados robustez e velocidade (Nelson e Illingworth, 1990). A esses pontos serão tecidas algumas considerações.

Desde que as redes neurais são adaptáveis (isto é, aprendem com a experiência) não há a necessidade de um modelo matemático a priori para a transformação entre a entrada e a saída. As RNs aprendem corretas respostas observando exemplos do mundo real. Com suficientes exemplos, as RNs exibem uma forte capacidade de generalização. E Generalização é definida como a capacidade de produzir uma resposta razoável para uma entrada similar (mas não exatamente igual) a uma entrada apresentada durante o treinamento. Essa adaptabilidade também facilita um retreinamento para lidar com pequenas mudanças dentro do ambiente sendo modelado (Haykin, 1994).

As RNs não são programadas, mas sim treinadas. Devido a essa característica, elas são melhores aplicadas a problemas cujas soluções requerem conhecimentos os quais são difíceis de especificar mas para os quais há uma abundância de exemplos (Sheppard e Gent, 1991). Isso faz com que as RNs sejam ideais para aplicações com uma riqueza de dados e uma pobre teoria. Elas aprendem e desenvolvem soluções ajustando seu conhecimento de acordo com os exemplos por meio de regras de

aprendizagem. Essas regras de aprendizagem são algoritmos eficientes de computação para o descobrimento de transformações não lineares apropriadas entre o espaço do problema e o espaço das soluções (Sheppard e Gent, 1991).

Nessa pesquisa, o espaço do problema representa uma coleção de dados obtidos a partir de sensores em tempo real e o espaço da solução é uma identidade declarando o estado do processo. Uma RN apropriadamente treinada deveria então ser capaz de responder prontamente e corretamente a uma entrada não vista anteriormente. Isso indicaria que a RN generalizou o conhecimento do domínio e não meramente ‘memorizou’ o conjunto de treinamento (Zurada, 1992)

As RNs são também mais robustas do que procedimentos sequenciais tradicionais. Devido a sua estrutura massivamente e paralelamente distribuída, o conhecimento é distributivamente armazenado através das interconexões gerando uma suave degradação na sua performance se os nós são destruídos. Essa característica de robustez também habilita a RN a abstrair características essenciais de dados com ruídos, incompletos ou parcialmente incorretos.

Em acréscimo, uma vez treinada, a eficiência computacional de uma RN torna-a capaz de prover rápidas respostas a subseqüentes entradas (Nelson e Illingworth, 1990). Isso é especialmente importante para tomada de decisão em tempo real.

Essas características das redes neurais resultam em algumas atrativas habilidades que incluem:

- Encontrar relacionamentos entre conjuntos de dados aparentemente não correlacionados e depois construir um conjunto de informações a partir deles;
- Encontrar relacionamentos que analistas humanos não podem descobrir devido suas limitações intrínsecas, quando por exemplo existem uma grande quantidade de pontos;
- Ter a habilidade e velocidade, diferentemente dos humanos, de analisar os conjuntos de dados referidos acima em uma fração de tempo.



O principal ponto fraco das redes neurais é que elas não são muito boas em justificar suas soluções e isso pode possivelmente resultar em problemas de aceitação pelo usuário. Para se ter uma boa visão das redes neurais é útil descrevê-las em relação aos sistemas especialistas e aos métodos estatísticos.

Tanto Sistemas Especialistas quanto RNs representam tipos de tecnologias inteligentes (Haykin, 1994). Eles tem de certa forma a mesma intenção, ainda que difiram significativamente em muitos aspectos. Ambos tem o objetivo comum de simular a inteligência humana para resolver problemas, usando métodos diferentes de representação e processamento do conhecimento.

Os Sistemas Especialistas simulam e formalizam o processo do raciocínio humano baseado em símbolos. Eles representam o conhecimento explicitamente na forma de regras ou estruturas e processam esse conhecimento de uma maneira sequencial. O aprendizado nos sistemas especialistas é formado externamente por meio da codificação do conhecimento extraído do domínio de um especialista.

As RNs, por outro lado, procuram imitar a estrutura e funções dos neurônios do sistema nervoso central. Elas representam o conhecimento implicitamente e distributivamente com os esforços (pesos) das interconexões entre os elementos do processamento (neurônios). Elas processam esse conhecimento de uma forma paralela aplicando um raciocínio indutivo no qual padrões gerais e regras são determinados a partir dos dados e experiência (Zahedi, 1991; Haykin, 1994). O aprendizado nas RNs acontece internamente por meio do ajuste dos pesos das interconexões durante a exposição dos exemplos. Assim como acontece em relação aos sistemas especialistas, existem similaridades e diferenças entre as RNs e as técnicas estatísticas clássicas.

As RNs, em fato, podem representar muitos conceitos estatísticos. Um simples *perceptron* (neurônio artificial), por exemplo, tem uma forte associação com a análise discriminante. Uma camada múltipla de *perceptrons* pode ser estatisticamente interpretada como uma função de regressão não linear estimada pela otimização de alguma medida de ajuste dos dados de treinamento (como por exemplo mínimos

quadrados). Os pesos representam os parâmetros de inclinação e os *bias* (ou *offsets*) representam os pontos de intersecção das retas com a origem. De uma forma similar, as RNs tem uma versão para a análise estatística de *Clusters* que se chama Aprendizagem não Supervisionada. (Cheng e Titterington, 1994).

É importante ressaltar que existe um paralelo que pode ser feito entre métodos estatísticos e redes neurais, conforme mostra a tabela 1.

**Tabela 4.1: Terminologia correspondente entre estatística e redes neurais.**

Estatística	Redes Neurais
Modelo	Rede
Estimação	Aprendizagem
Regressão	Aprendizagem supervisionado
Interpolação	Generalização
Observações	Conjunto de treinamento
Parâmetros	Pesos
Variáveis independentes	Entradas
Variáveis dependentes	Saídas
Regressão de Ridge	Decaimento dos pesos

Existe uma diferença fundamental, entretanto, na aproximação que essas duas técnicas usam para representar um ambiente real. Nos métodos estatísticos, os modelos matemáticos do ambiente são formulados primeiramente. Os parâmetros são então estimados e finalmente o modelo é validado. Com RN, a arquitetura de rede é primeiramente construída (pelas características do problema) e depois disso a rede é treinada para predizer respostas a um conjunto de dados de treinamento da melhor forma possível (Haykin, 1994). A solução é então obtida através da experimentação e simulação ao invés de ser através de uma aproximação formal (Zurada, 1992). Também, em estatística, algumas restrições são muitas vezes assumidas com respeito as distribuições que os dados devem ter. Nas RNs raramente, ou nunca, suposições são feitas sobre as distribuições dos dados. As RNs usam os dados para implicitamente

desenvolver o relacionamento funcional representando o ambiente (Cheng e Titterington, 1994).

### 4.3- Modelo do Neurônio Artificial

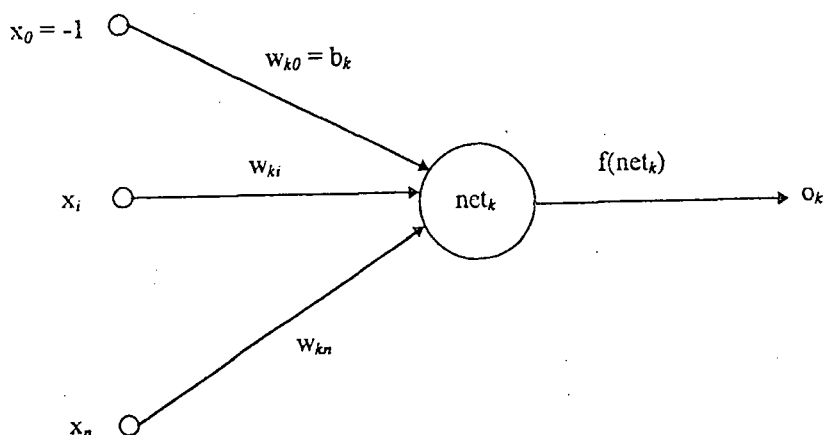
Uma estrutura comum em basicamente todas as RNs é o neurônio (nós ou elemento de processamento). Diferenças existem entre arquiteturas de redes e paradigmas de aprendizagem, mas desde que RNs são tipicamente compostas de camadas de neurônios (Kempka, 1994) é oportuno descrever primeiramente esse conceito básico.

Um neurônio básico (Figura 4.1) consiste das seguintes características: entradas, pesos, viés (ou *bias*), uma operação de somatório, uma função de ativação e uma saída. As entradas são representações numéricas das características de entrada do domínio do problema, podendo ser uma variável binária ou contínua (Lippman, 1987). Os pesos representam coeficientes adaptativos para cada uma das entradas (Nelson e Illingworth, 1990). O *bias* ( $x_0$ ) é um meio alternativo de representar o limiar (*threshold*) de um neurônio. O *bias* é tomado tipicamente de fora do corpo do neurônio e conectado a ele usando uma entrada adicional que permanece fixa (exemplo: +1). A função de somatório é o produto interno do vetor de entrada e vetor de pesos. A função de ativação transforma o resultado do somatório na saída do neurônio. Um neurônio básico opera da seguinte maneira: Ele soma as entradas ajustadas pelos pesos e passa essa soma através da função de ativação para produzir uma saída. Isso pode ser feito de uma forma binária ou contínua dependendo da função de ativação usada. Essa saída é então passada (em muitas arquiteturas) para neurônios subsequentes.

Esse processo pode ser matematicamente representado pela seguinte equação:

$$o_k = f\left(\sum_{i=0}^n w_i x_i\right)$$

**Figura 4.1: Modelo de neurônio artificial**



onde:

$i$  : entrada;

$k$  : saída do neurônio;

$x_i$  :  $i$ -ésimo elemento do vetor de entrada;

$o_k$  :  $k$ -ésimo elemento do vetor de saída;

$w_{ki}$  : peso conectando a  $i$ -ésima entrada ao neurônio  $k$ ;

$b$  : bias aplicado ao neurônio;

$w_{k0} = b_k$  : Efeito do bias conectado a uma entrada fixa igual a  $-1$ ;

$net_k$  : A atividade interna da rede do neurônio  $k$ . Ela representa a operação somatório e seu argumento é a função de ativação;

$f(net_k)$  : Função de ativação representando o relacionamento entre entrada e saída da função associada com o neurônio  $k$ .

O tipo da função de ativação é um aspecto muito importante na operação da RN. Uma boa descrição dos vários tipos dessas funções está bem sumarizado em Kempka (1994). O tipo mais simples consiste na função de ativação linear. Essa função simplesmente passa o resultado do somatório diretamente para a saída e podem variar no intervalo  $(-\infty, +\infty)$ . As categorias adicionais das funções de ativação são não lineares por natureza. A primeira dessas e mais simples funções impõem um limite rígido e operam de uma forma binária restringindo a saída para valores 0/1 ou  $-1/+1$ .

dependendo do intervalo escolhido. Um outro tipo impõe uma forma híbrida limitando os valores em um intervalo como acima e variando nesse intervalo de uma forma linear. Um terceiro tipo e mais largamente utilizado consiste numa função continuamente diferenciável que é fundamental para as RNs treinadas por *Backpropagation*. Relacionadas com esse último grupo estão as funções exponenciais, largamente utilizadas nas RNs probabilísticas e as funções gaussianas, utilizadas nas RNs com Função de Base Radial.

#### 4.4- Topologias das RNs

Existem essencialmente três fatores a serem considerados para a seleção de uma rede neural. O primeiro é como os neurônios processam as informações. Esse fator enfoca a determinação do somatório e da função de ativação, discutidos anteriormente. Um outro é como os pesos das conexões são modificados. Isso é determinado pelo tipo de paradigma de treinamento escolhido, que será discutido posteriormente. O último fator consiste na determinação da maneira com que os neurônios da rede são conectados, definindo a arquitetura ou topologia da rede. Em muitas circunstâncias esses fatores são influenciados pela definição do problema em questão.


A arquitetura de uma RN é definida pela conexão dos neurônios. Esse fator inclui não somente como as conexões são feitas mas também quantas camadas de conexões existem e a maneira na qual a informação flui através da rede. Existem basicamente duas maneiras pelas quais as redes neurais são categorizadas: uma é se as camadas das redes são total ou parcialmente conectadas e a outra é se a informação flui através da rede numa única direção ou em ambas as direções. Nas redes de direção única (*feedforward*) nenhuma saída de um neurônio pode servir como entrada para um outro neurônio na mesma camada ou em camada precedente (Nelson e Illingworth, 1990). As redes com ambas as direções (*feedback*), também denominadas de redes recorrentes são primeiramente utilizadas quando o ambiente a ser modelado é não estacionário (isto é, os parâmetros estatísticos dos sinais gerados no ambiente mudam com o tempo). Previsão de séries temporais, sistemas de controle e análise de sinais de fala são exemplos desses tipos de ambientes. A realimentação é introduzida porque uma

saída presente nesses tipos de ambientes são influenciadas por saídas anteriores no tempo (Zurada,1992).

Nessa pesquisa as características do ambiente variam com o tempo e por isso foram empregados os procedimentos de séries temporais descritos no capítulo anterior para, além de resolver o problema dos dados IID, tornar o uso das redes *feedforward* aplicáveis. Aplicadas aos resíduos das cartas de CEP em tempo real, os pontos de entrada das RNs aqui não são influenciados pelas medidas anteriores. Isso significa que as características essenciais do ambiente podem ser aprendidas pela rede via uma sessão de treinamento com um conjunto que é representativo desse ambiente. Uma vez completo o processo de treinamento, os pesos das conexões devem capturar as características subjacentes de tal ambiente (Haykin, 1994). A rede então utiliza o aprendizado das experiências passadas para prover soluções para diferentes entradas representativas do ambiente no qual as amostras de treinamento foram tomadas. Desde que as arquiteturas usadas nessa pesquisa são de natureza unidirecional (*feedforward*) uma breve revisão desse tipo de arquitetura será visto a seguir.

Uma RN *feedforward* de camada simples mapeia a entrada diretamente a uma camada de saída. A figura 4.2 ilustra uma RN de camada única consistindo de 4 entradas e 3 saídas.


**Figura 4.2: Uma RN de camada única.**



Uma RN *feedforward* multicamada consiste de uma ou mais camadas de neurônios entre as camadas de entrada e de saída, denominadas de camadas escondidas

ou ocultas (*hidden layer*). As entradas nessas redes se propagam de camada a camada resultando em um conjunto de respostas final (Haykin, 1994). Tais redes são mais flexíveis e podem ser usadas para representar funções de entrada/saída não lineares mais complicadas (Cheng e Titterington, 1994). Cybenko (1989) e Hornick, Stinchcomb, e White (1989) mostraram que uma RN multicamada *feedforward* com uma camada é suficiente para uniformemente aproximar qualquer função contínua. A camada escondida de neurônios atua como um meio de habilitar a rede para extrair as características mais significativas das entradas (Haykin, 1994). Isso significa que tal rede pode aprender a representar superfícies de decisões mais complexas para separar classes de padrões (Beale e Jackson, 1992). Essa capacidade aumenta com uma boa escolha da função de ativação. A Figura 4.3 ilustra uma rede *feedforward* multicamada consistindo de 4 entradas, 3 neurônios na camada escondida e 3 saídas.

**Figura 4.3: Uma rede *feedforward* multicamada.**



#### 4.5- O Aprendizado nas RNs

Como mencionado anteriormente, um dos pontos positivos das RNs é a sua habilidade de aprender a partir de exemplos e melhorar o seu desempenho através do aprendizado. O aprendizado em geral pode ser descrito como uma mudança relativamente permanente no comportamento trazida pela experiência (Zurada, 1992). Nas RNs o aprendizado pode ser definido como um processo no qual os pesos são adaptados através de contínuas estimulações pelo ambiente (Haykin, 1994). O objetivo da aprendizagem é um melhoramento no modo no qual as RNs respondem ao ambiente,

isto é, uma mais precisa aproximação do mapeamento da relação funcional entre entrada e saída. Assim o objetivo do aprendizado é determinar os valores ótimos dos pesos que forneçam a melhor aproximação a uma função desejada, contínua e multivariada, baseada nos exemplos de treinamento (Zurada, 1992). A seguir serão brevemente descritos alguns paradigmas de aprendizagem: supervisionado, reforço (*reinforcement*), não supervisionado e híbrido.

No aprendizado supervisionado conjuntos de treinamentos compostos de pares de entradas e saídas são apresentados à rede. As entradas, conhecidas a priori, são apresentadas à camada de entrada e as ativações se propagam em um sentido através da rede para produzir uma saída. A saída desejada, também conhecida a priori, representa o resultado de uma ação ótima a ser executada pela rede. O treinamento da rede é obtido pela modificação dos pesos internos das conexões através da influência da combinação do vetor de treinamento e da diferença entre a saída processada e a saída desejada (Sheppard e Gent, 1991; Haykin, 1994). Essa modificação de pesos ocorre em um modo iterativo para minimizar uma medida de desempenho (por exemplo, erro médio quadrático entre os vetores processados e calculados). O método predominante utilizado em aprendizado supervisionado é o algoritmo de *Backpropagation* do erro. A desvantagem do aprendizado supervisionado é que valores da resposta para cada padrão de treinamento devem ser conhecidos. Quando essa limitação pode ser superada, o aprendizado supervisionado se torna sempre a ótima alternativa. Contudo, o aprendizado com reforço pode sobrepor essa limitação (Zurada, 1992; Haykin, 1994).

O aprendizado com reforço pode ser usado quando a informação é parcialmente disponibilizada sobre a certeza da resposta da rede (isto é, sabe-se se a saída é correta ou incorreta). No aprendizado supervisionado a informação é provida sobre como a rede neural deveria moldar seu comportamento para melhorar o seu desempenho. No aprendizado com reforço, a rede é graduada em seu desempenho mas não é provida a informação sobre a possibilidade de um melhoramento ou como a rede deveria mudar o seu comportamento (Haykin, 1994).



No aprendizado não supervisionado a rede não é provida com uma saída desejada para ser usada no melhoramento de seu comportamento e o conjunto de treinamento consiste de somente entradas. A rede tenta, nesse caso, descobrir aspectos comuns entre as entradas separando os padrões entre si. Os pesos nessas redes são modificados assim que o processo ocorre (Zurada, 1992). Devido a essa modificação dos pesos, o aprendizado não supervisionado é também comumente referido como aprendizado auto organizado. Nesse tipo de aprendizagem os padrões de entradas são divididos em grupos (*clusters*) baseados em critérios de similaridades (Haykin, 1994). Cada *cluster* representa uma categoria e o aprendizado ocorre assim que a rede auto ajusta os seus pesos de tal forma que entradas similares produzem a mesma resposta (Sheppard e Gent, 1991).

As redes neurais usando o paradigma de uma aprendizagem híbrida tipicamente tem uma fase não supervisionada seguida de uma fase supervisionada. Uma rede com Função de Base Radial, por exemplo, pode ser um caso de aprendizagem híbrida e esse tipo de aprendizagem pode prover um melhoramento nas soluções com respeito ao uso de um único paradigma (Haykin, 1994). Sheppard and Gent (1991) expõe os benefícios potenciais do uso de um sistema de aprendizado híbrido que pode ser sintetizado pelas idéias seguintes. O sucesso de qualquer técnica de treinamento de uma RN é totalmente dependente da existência de um conjunto de treinamento. No aprendizado supervisionado a classificação de um padrão envolve o treinamento da rede por exemplos estatisticamente representativos do padrão a ser classificado. Isso coloca uma forte restrição a problemas de classificação de padrões onde somente um grupo pequeno de exemplos, ou nenhum exemplo de padrões de interesse são disponíveis. O uso de um paradigma de aprendizado híbrido pode responder melhor a esse tipo de problema. A fase auto organizada pode servir para alocar recursos para a rede de uma forma significativa definindo os centros das funções de base radial naquelas regiões onde dados significantes estão presentes. A rede deveria ter então a habilidade de identificar padrões usando medidas entre as *clusters* e o resultado obtido (*match*).

#### 4.6- Classificação de Padrões

A seleção de uma arquitetura e um paradigma de aprendizagem é fortemente influenciado pela tarefa que a RN é requerida a executar. As RNs tem sido desenvolvidas e usadas com sucesso para resolver muitas tarefas complexas como associação, controle, previsão e classificação de padrões em domínios como previsão financeira, diagnose médica, robótica, reconhecimento de fala e processos de manufatura (Haykin, 1994). Desde que o ponto crucial dessa pesquisa é a identificação de padrões de CEP, o restante desse trabalho irá enfocar somente a tarefa de classificação de padrões.

Nessa tarefa, existe um número fixo de categorias (classes) no qual as entradas da rede serão classificadas (Ripley, 1994). A rede é treinada com padrões de entrada e suas categorias correspondentes. A vantagem de se usar uma RN para tal tarefa consiste em sua habilidade em construir regiões de decisão não lineares entre as diferentes classes de uma forma não paramétrica (Haykin, 1994). Isso pode ser explicado geometricamente pois os padrões são geralmente representados por vetores  $n$ -dimensionais do espaço euclidiano e a RN mapeia esses pontos em determinadas regiões de acordo com as categorias apropriadas. Essas regiões de decisão são separadas por fronteiras de decisão ou superfícies, geralmente de dimensão  $n$  (Zurada, 1992). Desde que muitas tarefas de classificação envolvem uma grande quantidade de dados, muitas vezes complexos, as RNs provêem um eficiente método de ajuda para os humanos nessa tarefa de classificação.

#### 4.7- Uma Pequena Análise de Resultados da Literatura

Em uma análise de 21 casos, de 1989 a 1995, comparando RNs com outras técnicas (Classificação Bayesiana, Árvores de Decisão Binárias, Predição Linear, Regressão Linear Múltipla e Classificação pelo Vizinho Mais Próximo (*Cluster*) e Sistemas Especialistas) sobre vários domínios, as RNs superaram essas técnicas em 18 casos (Decatur, 1989; Renals e Rohwer, 1989; Maloney, 1990; Rogers, Ruck, Kabrisky e Tarr, 1990; Smotroff, Howells, e Lehar, 1990; Brown, Bergondy, e Archer, 1991;

Tang, Wee, e Han, 1991; Lure, Chiou, Yeh, e Grody, 1992; Tam e Kiang, 1992; Leung, Blanchette, e Haykin, 1993; Serpico, Roli, Pellegretti, e Vemazza, 1993; Whittington, Spracklen, Haugh, e Faulkner, 1993; Refenes, Zaprais, e Francis, 1994; Toborg, 1994; Antonio, 1995; Bissessur e Naguib, 1995; Chakrabarti, Bindal, e Theugharajan, 1995; Corcoran e Lowery, 1995; Moreno, Pineiro, Sanchez, iqanas, Merino, Acosta e Hamilton, 1995; Nekovei e Sun, 1995). As RNs tiveram bons resultados em relação aos métodos estatísticos clássicos pois sua natureza não paramétrica não necessita assumir considerações sobre a forma da distribuição dos dados (Chau e Geraniotis, 1991). É especialmente difícil estimar a função densidade de probabilidade em uma dimensão maior e não é conveniente usá-la para a discriminação de regiões onde as densidades das classes são comparadas (Jordan e Choe, 1992; Ripley, 1994). Brown, Bergondy e Archer (1991) também defendem que as RNs podem mapear melhor as superfícies de decisões complexas. Devido a problemas de clareza, elucidação de conhecimento e eficiência computacional as RNs podem desempenhar melhores resultados do que os Sistemas Baseados em Conhecimento (Whittington e Spracklen, 1990).

## ***Capítulo 5 – Reconhecimento Neural de Padrões em CEP***

---

### **5.1 Introdução**

Os resíduos gerados de acordo com o modelamento do capítulo 3 são agora submetidos a um método que avalie o CEP de uma forma eficiente também em tempo real. Suprimido agora o problema da correlação serial, a morfologia dos dados pode ser verificada usando o CEP, uma vez que os requisitos básicos das cartas de controle não são violados. Como mencionado no capítulo 2, as técnicas convencionais tem seu uso bastante restrito nos processos sob o regime em tempo real e por isso o uso de redes neurais artificiais se tornam um ótimo caminho alternativo para o reconhecimento de padrões das cartas de CEP de uma forma automática.

Algumas limitações nesse trabalho simulado foram impostas ao processo não constituindo um grande problema para a sua implementação em casos reais. São elas:

1) O processo precisa estar sobre controle:

Conforme mencionado no capítulo anterior, um técnico é levado a ajudar na definição do estado do processo. Isso foi usado para se evitar o uso de redes neurais não supervisionadas. Futuramente isso certamente consistirá em um tópico de pesquisa.

2) A suposição da normalidade foi assumida no processo:

A definição da suposição de normalidade é comumente utilizada na análise do CEP. O Teorema Central do Limite procura justificar a adoção dessa medida, contudo numa pesquisa futura uma melhor adequação das distribuições de probabilidade deverá ser investigada.

3) As observações são obtidas em intervalos regulares de tempo:

Isso é comumente uma prática na grande maioria dos conversores analógicos digitais, não constituindo uma limitação também para a maioria dos processos automatizados.

Seguintes a essa introdução será apresentado na seção 5.2 alguns resultados de trabalhos anteriores. Na seção 5.3 será visto como foi obtido o banco de dados dos padrões de treinamento e teste das redes neurais. Um tratamento especial será mostrado para alguns tipos especiais de padrões na seção 5.4, abordando problema da invariância para padrões cíclicos e o deslocamento da média. Os experimentos iniciais com a rede neural Fuzzy-ARTMAP, fazendo uso do programa computacional *The ART Gallery*, são descritos na seção 5.5. Na seção 5.6 os experimentos com a rede neural RBF serão descritos. Os resultados de tais experimentos são descritos na seção 5.7.

## 5.2 Técnicas Convencionais, Sistemas Especialistas e Redes Neurais Artificiais

Muito embora o reconhecimento de padrões estatístico usando recursos numéricos e heurísticas tem sido utilizados nos importantes trabalhos de Swift (1987), Cheng(1989) e Pham e Oztemel(1992a), esse trabalho usa a vantagem das redes neurais artificiais seguindo principalmente algumas direções dos trabalhos de Hwarng e Hubele (1991), Pham e Oztemel(1992b) e Tontini(1995). A capacidade de reconhecimento de padrões conforme apresentou Lippmann(1989) tem sido mostrada como superior aos sistemas convencionais usando hipóteses estatísticas, *templates* e heurísticas. Isso se deve principalmente devido a dificuldade de um sistema especialista necessitar de um conhecimento a priori. Por meio de redes neurais esse conhecimento tende a ser minimizado pelo especialista que projeta a rede neural fazendo um maior trabalho *off line*.

Alguns trabalhos tem comparado o resultado do reconhecimento de padrões de CEP usando técnicas convencionais, sistemas especialistas e redes neurais artificiais. Muito embora não tenha sido utilizado um mesmo banco de dados, a condução dos experimentos tenha sido diferente, os tipos de padrões também diferentes, os casos práticos não serem investigados, etc.... as tabelas seguintes mostram resultados destacando um futuro promissor para os sistemas baseados em redes neurais.

Tabela 5.1: Resultados de Pham e Oztemel

Técnica	Nº de épocas de treinamento	Performance de treinamento (%)	Performance de teste (%)
Heurística	--	--	94.18
Backpropagation	200	100	95
LVQ - padrão	70	95.18	92.31
LVQ2	4	94.31	89.6
LVQ(padrão)+LVQ2	74	96.18	92.61
LVQ (com Consciência)	70	95.99	92.71
LVQ-x	20	100	97.7

Fonte:Pham e Oztemel (1994)

Obs.:A rede LVQ alcançou um resultado de quase 98% de classificação correta com apenas 20 épocas de treinamento!

Tabela 5.2: Resultados de Tontini.

	Sistemático	Desvio positivo da média	Desvio Negativo da média	Diminuição da variabilidade	Ciclo	Mistura	Média geral	S
RBF	80.6	88.6	90	99.6	62	83.6	84.1	12.6
Fuzzy ARTMAP	77	88.6	93	98.3	51.6	70.6	79.8	17.1
Rbf-Fuzzy ARTMAP	78	86.3	88.3	99.3	60.6	82.6	82.5	14.5

Fonte: Tontini(1995).

Obs.: Desempenho comparativo de 3 redes neurais em relação a diversos padrões de CEP. Resultados excelentes para muitos padrões.

Tabela 5.3: Resultados de Smith

Conjunto de treinamento ou teste	Entradas	Tamanho da camada oculta	Porcentagem de erros	
			Redes Neurais	Cartas de Controle
A	Todas	3	16.8	27.5
A	Todas	10	11.7	27.5
A	Estatísticas	3	28.5	27.5
B	Todas	3	0.8	0.5
B	Todas	10	0.5	0.5
B	Estatísticas	3	0.0	0.5

Fonte: Smith (1994)

Obs.: Duas amostras A e B com 500 observações e diferentes parâmetros, aplicados como cartas de controle sem processamento (todas) e com pré-processamento (estatísticas). A rede *Backpropagation* foi utilizada e mostrou resultados superiores.

Tabela 5.4: Resultados de Guo e Dooley.

Deslocamento da Média (k)	Variância (c)	Taxa de Erro			
		Rede Neural	QDF	Heurística 1	Heurística 2
0.25	-	0.01	0.057	0.491	0.056
0.5	-	0.009	0.007	0.411	0.011
0.75	-	0.019	0.003	0.368	0.007
1	-	0.023	0.005	0.294	0.012
1.25	-	0.038	0.013	0.241	0.023
1.5	-	0.078	0.023	0.210	0.031
1.75	-	0.118	0.038	0.207	0.031
2	-	0.182	0.056	0.193	0.080
Média de k		0.06	0.025	0.302	0.031
-	1.5	0.084	0.118	0.314	0.222
-	1.75	0.069	0.101	0.359	0.205
-	2	0.063	0.089	0.394	0.198
-	2.25	0.055	0.079	0.441	0.186
-	2.5	0.044	0.076	0.456	0.174
-	2.75	0.045	0.075	0.467	0.174
-	3	0.037	0.071	0.492	0.156
Média de c		0.057	0.087	0.418	0.188
Média combinada		0.058	0.056	0.360	0.109

Fonte: Guo e Dooley (1992)

Obs.: Resultados comparativos entre redes neurais, função discriminante quadrática (QDF) e duas heurísticas para diversos deslocamentos da média e diversos níveis de variância.

Também interessantes são as comparações de Cook (1998), abordando deslocamentos da média; Hwang e Hubele (1994) considerando a rede *Backpropagation* e a rede de Boltzman e também Cheng considerando sistemas especialistas.

Um fato que se pode perceber a partir de comparações como as citadas acima é que a escolha da arquitetura da rede neural em si não tem sido um grande problema para aplicações como estas. Com o advento de novos recursos computacionais, a velocidade do processamento tem possibilitado uma saudável concorrência por cada vez melhores resultados e possibilitando o uso de inúmeras novas arquiteturas de redes neurais. Nesse trabalho foram feitas simulações envolvendo uma série de redes neurais contrastando suas peculiaridades, suas arquiteturas, sua dificuldade de implementação computadorizada, além de outros aspectos particulares como velocidade de aprendizagem, resultados do reconhecimento de padrões, etc.... As seguintes redes foram assim simuladas: *Backpropagation*, LVQ, RBF, ARTMAP e Fuzzy-ARTMAP.

Por uma escolha pessoal, devido principalmente a facilidade de implementação computadorizada na condução dos experimentos, a rede neural RBF foi finalmente escolhida para um maior detalhamento da metodologia e uso na aplicação do capítulo 6. Contudo, a substituição da RBF por uma nova arquitetura de rede neural fica aqui facilitada e pesquisas futuras deverão dar um caráter estimulante a essa área. Na realidade, os resultados gerais alcançados usando a rede Fuzzy-ARTMAP (com as limitações intrínsecas de um pacote computacional não flexível) foram superiores aos resultados alcançados pela rede RBF; contudo, o desenvolvimento de toda a metodologia em tempo real ficou comprometido devido a sua dificuldade de implementação. Além disso, no trabalho de Tontini(1995) a rede RBF alcançou melhores resultados de classificação do que a rede Fuzzy-ARTMAP e a rede RBF Fuzzy-ARTMAP. A escolha da RBF permitiu a implementação de um código computacional que pode ser visto no anexo C.

### 5.3 - Construção do Banco de Dados

Na geração dos padrões aleatórios e não aleatórios de CEP para treinamento e teste das redes neurais os principais cuidados a serem tomados estão relacionados com a sua adequada representação das situações reais dos padrões de um processo, evitando ambigüidade entre os padrões e tendo cada padrão uma representação balanceada. A construção desse conjunto apesar de simples envolve um grande número de parâmetros para os diversos padrões de treinamento. Os passos seguintes descrevem sucintamente como foi feita a escolha do conjunto de padrões para treinamento e teste das redes neurais:

#### *a) Avaliar e determinar os parâmetros dos padrões:*

Conforme mostram as equações do anexo A, alguns parâmetros como amplitude, nível de ruído, período de ciclo, etc..., são responsáveis pela implementação dos padrões. A escolha inicial desses parâmetros foi feita heurísticamente usando valores similares de parâmetros para todos os padrões. Com o procedimento de refinamento dos passos seguintes chegou-se a um conjunto final de parâmetros conforme mostra a tabela



5.5. Foi investigado se a heurística inicial teve muita importância na definição final dos parâmetros, adotando valores iniciais diferentes, mas o resultado dos valores dos parâmetros finais mostrou ser bastante similar.

**Tabela 5.5: Valores dos parâmetros usados para as diversas classes de padrões.**

<b>Tendência</b>	<i>Sinal</i>	Crescente (+) e decrescente (-)
	<i>Inclinação</i>	0.20, 0.30, 0.25 e 0.35
	<i>Valor inicial do ruído</i>	0.0
	<i>Incremento do ruído</i>	0.025
	<i>Valor Final do ruído</i>	0.25
<b>Ciclo</b>	<i>Período</i>	8
	<i>Amplitude</i>	1.5, 2.0 e 2.5
	<i>Valor inicial do ruído</i>	0.0
	<i>Incremento do ruído</i>	0.05
	<i>Valor Final do ruído</i>	0.25
<b>Estratificação</b>	<i>Off set</i>	-0.20, 0.0 e 0.20
	<i>Valor inicial do ruído</i>	0.10
	<i>Incremento do ruído</i>	0.05
	<i>Valor Final do ruído</i>	0.25
<b>Sistemático</b>	<i>Parâmetros</i>	1.5, 2.0, 2.5
	<i>Ruídos</i>	0.0, 0.10, 0.15, 0.25
<b>Mistura</b>	<i>Parâmetros</i>	1.75, 2.0, 2.25
	<i>Ruídos</i>	0.0, 0.10, 0.15, 0.25
<b>Deslocamentos</b>	<i>Sinal</i>	Positivo(+) e Negativo (-)
	<i>Parâmetros</i>	1.5, 2.0, 2.5
	<i>Ruídos</i>	0.0, 0.10, 0.15, 0.25

#### *b) Triagem preliminar*

Foi usada uma rede neural, treinada preliminarmente sem bons resultados, para eliminar padrões de treinamento que foram contraditórios, ou seja, que foram classificados erroneamente (por exemplo, um padrão de mistura sendo classificado como sistemático). Uma melhor rede neural foi obtida com o novo conjunto de padrões e esse processo foi repetido até um resultado ótimo de classificação com respeito aos erros tipo I e tipo II.

c) *Avaliação do Erro Tipo II (balanceamento da rede)*

A tabela seguinte mostra o esquema clássico dos erros tipo I e tipo II para o problema do CEP.

**Tabela 5.6: Erros tipo I e tipo II.**

		Situação Real	
		CEP sob controle	CEP Fora de Controle
Tomada de Decisão	CEP sob controle	O.K. Sob controle	Erro II Sob Controle
	CEP Fora de Controle	Erro I Fora de Controle	O.K. Fora de Controle

Os erros acima descrevem os dois tipos de erros que podem ocorrer na utilização da maioria dos algoritmos que lidam com o reconhecimento dos padrões de CEP. O primeiro, Erro Tipo I, resulta quando o algoritmo detecta um padrão não aleatório qualquer quando ele de fato não existe (ou seja, o processo está sobre controle e o algoritmo diz que não está). O segundo, Erro Tipo II, é quando o algoritmo deixa de detectar um padrão não aleatório quando ele de fato existe. Nesse caso, o processo não está sob controle e o algoritmo diz que está.

Nesse contexto, levando em conta o Erro Tipo II, a seguinte medida foi considerada:

$$R_o = n_o / N_o,$$

onde:

$o$ : classe de padrão ( $o=1$  para ciclo,  $o=2$  para tendência, ...);

$n_o$ : número de padrões fora de controle classificados como sob controle;

$N_o$ : número total de padrões da classe  $o$ .

A idéia é manter a razão  $R_o$  em um mesmo nível para todas as classes segundo um intervalo  $r_l \leq R_o \leq r_h$ , onde  $r_l$  e  $r_h$  são os limites inferiores e superiores da razão, respectivamente. Se a razão  $R_o < r_l$  ou  $R_o > r_h$  o passo (a) deve ser refeito; em caso contrário, o passo (d) é executado.

#### d) Avaliação do Erro Tipo I

A idéia aqui é similar ao passo (c) sendo definida uma razão levando em conta o Erro Tipo II:

$$D_o = s_o / N,$$

onde:

$s_o$  : número de padrões sob controle classificados como fora de controle;

$N$  : número total de padrões sob controle.

A idéia também é manter a razão  $D_o$  em um mesmo nível para todas as classes segundo um intervalo  $d_l \leq D_o \leq d_h$ , onde  $d_l$  e  $d_h$  são os limites inferiores e superiores da razão, respectivamente. Se a condição acima é satisfeita o conjunto de dados é obtido, em caso contrário, o procedimento é repetido a partir do passo (a)

O procedimento acima foi aplicado iterativamente e com isso foi obtido um bom balanceamento de padrões para a entrada das redes neurais e sobretudo os padrões não mostraram ambigüidade no sentido de fornecer uma boa indicação de causas assinaláveis de variação, auxiliando assim o operador ou possibilitando a inserção de agentes inteligentes numa posterior etapa de tomada de decisão. Foram dessa forma obtidos 489 vetores representando as 6 classes de padrões de CEP.

Um outro ponto importante consiste na definição do número de observações de cada vetor representando a carta de controle, aqui denominado de "janela de CEP". Tal janela foi definida de acordo com a probabilidade teórica de se cometer o erro tipo I para cada padrão não aleatório quando o processo está sobre controle. Por exemplo, considere a chance de uma seqüência de observações representarem um padrão de estratificação (com parâmetros de  $\pm 1$  desvio padrão) em um processo normal. A probabilidade de que  $n$  observações estejam estratificadas em seqüência é 0.217 para  $n=4$ , 0.1482 para  $n=5$ , 0.1012 para  $n=6$ , 0.069 para  $n=7$  e 0.047 para  $n=8$ . Como pode ser visto, existe um alto valor para o erro tipo I para um número pequenos de observações. Por outro lado, quando a janela de pontos se torna grande, o tempo de classificação pode comprometer a aplicação do CEP bem como o número de neurônios

da rede neural ser grandemente expandido. Assim, para o grande escopo de aplicações em tempo real, o número de oito pontos para a janela de CEP pode ser considerado um bom número de escolha.

Alguns procedimentos para a construção do banco de dados foram desenvolvidos e são a seguir resumidamente descritos. Os conjuntos de treinamento e de teste para as redes neurais foram construídos separadamente devido a certas peculiaridades.


### Conjunto de Treinamento

Sendo aqui utilizado o treinamento supervisionado o conjunto de entradas da rede neural contém assim os 6 padrões não aleatórios de CEP descritos anteriormente, além do conjunto de padrões representando o processo sob controle.

#### *a) Geração de amostras do processo sob controle*

Como ponto de partida, a rede neural deve ser capaz de aprender quando o processo está sobre controle para investigar as medidas de desempenho principalmente em relação aos erros tipo I e tipo II. A figura 5.1 mostra o processo de geração dos padrões de normalidade do banco de dados de treinamento. Foi aqui usada a orientação dos trabalhos de Hwang e Hubele (1993), Guo e Dooley (1992) e Tontini(1995).

**Figura 5.1: Geração dos padrões normais de treinamento.**



Nesse esquema são geradas  $n$  observações a partir de uma distribuição normal  $N(0,1)$  constituindo um gráfico de CEP. Em seguida é feito um teste de normalidade

sobre esse gráfico e caso o processo não seja normal devido ao teste uma nova carta deve ser gerada.


Foram utilizados aqui, alguns procedimentos do programa MatLab, e a semente de geração dos números aleatórios foi mantida após a inteira construção do banco de dados para uma posterior repetição dos experimentos.

Na geração desses padrões aleatórios, ponto de partida para a construção de todas as cartas de controle, alguns procedimentos de teste da normalidade foram construídos no sentido de limitar a existência de pontos fora dos limites de controle, de limitar os desvios da média e de auxiliar na monitoração da variabilidade do processo e na discriminação entre alguns tipos de padrões. Tais testes se resumem nas cartas de Shewhart para pontos individuais, no uso da estatística envolvendo a Soma dos Quadrados dos Desvios e também da carta CUSUM. A seguir são então, resumidas as etapas do processo da figura 5.1.

#### *a.1) Gerar $N(0,1)$*

Aqui são geradas  $n$  observações segundo uma distribuição normal com média 0 e desvio padrão 1 como mostra a figura 5.2.

**Figura 5.2: Geração de amostras normalmente distribuídas.**



A equação que define a geração dos números aleatórios pode ser simplificada pela expressão:

$$y(t) = \mu + a(t)$$

com média  $\mu=0$  e ruído  $a(t)$  com média também 0 e variância  $\sigma^2=1$ .

#### *a.2) Processo é Normal?*

Para que se consiga uma boa representatividade dos padrões gerados, não basta que eles sejam gerados por suas respectivas equações. É preciso garantir que algumas condições iniciais sejam satisfeitas. Não raro ocorre que uma carta de controle gerada aleatoriamente segundo uma distribuição normal apresenta padrões não aleatórios. Os testes a seguir tem a função de monitorar esse problema e também servem para definir a priori se um processo está sob controle para a escolha do modelo autoregressivo definido no capítulo 3. Tais testes foram usados a medida que a pesquisa foi se desenvolvendo e testados em conjunto eles provaram ser redundantes. A escolha por apenas um dos testes de normalidade provou ser suficiente.

### *Teste de Shewhart para Pontos Individuais*

Simulando um processo onde as observações são obtidas uma a uma, a escolha de um gráfico de controle para monitorar a existência de pontos discrepantes recai naturalmente sob a carta de Shewhart para pontos individuais.

Os limites de controle são facilmente calculados pelas seguintes expressões :


$$\left. \begin{matrix} LSC \\ LIC \end{matrix} \right\} = \mu_0 \pm z_{\alpha/2} \sigma_0, \quad X_1, X_2, \dots, X_m \sim N(0,1)$$

$$\hat{\sigma}_0 = \sqrt{\Delta/2}, \quad \Delta = \frac{1}{m} \sum_{i=1}^{m-1} (X_{i+1} + X_i)^2$$


$$\alpha = 5\%, \quad m = n^\circ \text{ de amostras}$$

e um gráfico característico é mostrado na figura 5.3.

**Figura 5.3: Exemplo de gráfico de Shewhart para pontos individuais com  $m=60$ .**



**Figura 5.4: Esquema do cálculo de Médias e Desvios.**



A aplicação do teste consiste basicamente no seguinte: se um ou mais pontos gerados segundo uma distribuição normal  $\sim N(0,1)$  ultrapassa os limites de controle uma nova carta deve ser então gerada.

$SSQ_t$  (Soma dos Quadrados dos Resíduos)

A estatística  $SSQ_t$  proposta por Guo & Dooley (1992) foi também utilizada. A equação seguinte descreve a estatística  $SSQ_t$ , que utiliza as  $k$  últimas observações da carta de controle ( $t_2 - t_1 + 1 = k$ ) e possui assim uma distribuição quiquadrado com  $k-1$  graus de liberdade.  $SSQ_t$  será comparada com os dois limites de controle da distribuição quiquadrado. A região crítica desses limites de controle definem a rejeição da hipótese nula da homogeneidade da variância.

$$SSQ_t = \sum_{t=t_1}^{t_2} y_t^2$$

Uma também promissora alternativa para o cálculo de  $SSQ_t$ , também proposta por Guo & Dooley (1992), pode ser obtida pela seguinte expressão:


$$SSQ_t = \sum_{i=0}^{15} \sum_{t=t_2 - ((i.n) + n)}^{t_2 - (i.n)} (y_t - média_i)^2$$

Tal procedimento foi utilizado inicialmente nos experimentos com a Fuzzy-ARTMAP para  $m=60$  observações. Aqui, o cálculo de  $SSQ_t$  se dá em torno das médias de cada 4 pontos consecutivos como mostra a figura 5.4.  $SSQ_t$  deve ser testada a partir de uma distribuição quiquadrado com 14 graus de liberdade. Este cálculo, contudo, reduz a sensibilidade do teste a aumentos ou diminuições da variabilidade das cartas de CEP e não é efetivo para um número menor de observações. Por essas razões esse teste não foi empregado no uso com a rede RBF.

*CUSUM (Gráfico de Somas Acumuladas - Cumulative Sums)*

Um último teste acerca da normalidade dos dados foi feito através do gráfico de CUSUM que tem também a finalidade de auxiliar na monitoração dos desvios da média de um processo. Para um maior aprofundamento sobre as cartas de CUSUM, o livro de Mittag (1993) é uma ótima referência.

**Figura 5.5:Gráfico de controle CUSUM usando máscara V.**




Aqui a carta CUSUM foi implementada em sua forma tabular no programa MatLab (poderia ser também feito usando máscara V como exemplifica a figura 5.5 a partir do programa Statistica) e dois parâmetros positivos K e H são utilizados. Nesse procedimento, duas variáveis são definidas pelas fórmulas:

$$S_i^+ = \sum_{j=1}^i (\bar{X}_{jn} - \mu_0 - K)$$
$$S_i^- = \sum_{j=1}^i (\bar{X}_{jn} - \mu_0 + K)$$

e testa-se se as realizações  $S_t^+$  e  $S_t^-$  ultrapassam os limites de decisão  $[-H;H]$ . Os valores de referência de K são freqüentemente adotados como metade da amplitude do deslocamento da média  $\gamma=\mu-\mu_0$  que se deseja rapidamente identificar. A figura 5.6 exemplifica o gráfico CUSUM em sua forma tabular.

**Figura 5.6:Gráfico de controle CUSUM usando forma tabular.**





### *a.3) Armazena Padrões*

Os diversos vetores representando as cartas sob controle são armazenadas em um arquivo único. A todos esses vetores está associado uma resposta com valor 0. Nesse arquivo estarão adicionados também os padrões não aleatórios e será, com os procedimentos de seleção dos parâmetros de geração dos padrões finais, reduzido a um conjunto com 489 vetores.

### *b) Geração de amostras de padrões não aleatórios para treinamento*

Aqui são implementadas as equações descritas no anexo A. Tais equações apresentam um conjunto de vetores de entrada para as redes neurais com as suas respectivas respostas. Para um melhor desempenho na tarefa de classificação das redes, as seis classes de padrões definidas anteriormente foram subdivididas em classes menores discriminando também os valores dos parâmetros para cada classe. Os seis padrões e suas respostas definidos inicialmente foram:

**Tabela 5.7: Representação inicial dos padrões.**

<b>Padrões</b>	<b>Resposta</b>
Tendência Crescente (TC)	1
Tendência Decrescente (TD)	2
Ciclo 1(C1)	3
Ciclo 2(C2)	4
Sistemático(SI)	5
Mistura(MI)	6
Estratificação(ES)	7
Desvio Crescente (DC)	8
Desvio Decrescente(DD)	9

Dessa forma todo o conjunto de treinamento é gerado automaticamente abrangendo o escopo de padrões não aleatórios. Sendo gerado *off line*, tal banco de dados representa também um abrangente escopo de possibilidades de causas assinaláveis existentes em um processo automatizado de CEP. Como resultado desse processo de geração e de um procedimento interativo de seleção de parâmetros foram obtidos todos os 6 padrões de CEP abordados nessa pesquisa. É importante lembrar que


o número de observações por vetor foi aqui fixado em 8. Inicialmente, contudo, nos experimentos iniciais com a rede Fuzzy-ARTMAP, um conjunto maior de pontos foi heurísticamente adotado servindo de base para a definição dos parâmetros da rede RBF.

### Conjunto de Teste

Os padrões de teste são construídos basicamente da mesma maneira, adicionando níveis de ruído aos parâmetros, testando assim a capacidade de generalização da rede, ampliando a sensibilidade de reconhecimento dos padrões. Foram também incluídos aqui os padrões de normalidade e, como comumente é feito em uma situação prática, o resultado de normalidade é adotado se todos os testes falharem.

Uma importante diferença entre os padrões de treinamento e os padrões de teste na construção do banco de dados se refere ao modo de inserção de observações no vetor que representa a carta de controle. Cada vetor representando uma carta de controle é nas janelas de teste definido com um número de observações variáveis com o intuito de se calcular as várias medidas de desempenho para a rede neural. A figura seguinte mostra como nas situações práticas, estando o processo sob controle há uma consecutiva inserção de pontos não aleatórios no gráfico até que o padrão não aleatório seja identificado apresentando um ponto com valor discrepante ou uma seqüência com padrão não aleatório. Essa inserção de pontos tem assim o intuito de simular um processo real onde os padrões não aleatórios vão surgindo com o tempo.

**Figura 5.7: Deslocamento da janela de pontos.**




Por meio desse mecanismo, pode ser também obtido o *ARL* (*Average Run Length*) e o número de observações necessárias para a determinação do reconhecimento de padrões não aleatórios. A função *ARL* é um poderoso instrumento que descreve a performance das cartas de controle (a CCO- Curva Característica de Operação também pode fazer isso). Tal função representa a expectância da variável aleatória *Run Length* que é o número de observações que ocorrem entre duas intervenções consecutivas em um processo. A função *ARL* de uma carta de controle mostra como os valores de *ARL* dependem do estado do processo. Quando um processo está sob controle, esta função deveria possuir altos valores e para processos fora de controle, a função deveria apresentar baixos valores.

#### 5.4 - Padrões Cíclicos

Dois principais problemas ocorrem no tratamento de padrões que dependem da fase dos pontos da carta de CEP como nos casos dos padrões cíclicos como mostrados na figura seguinte. O primeiro está relacionado com o período do ciclo investigado e o segundo consiste na ordem em que esse ciclo é apresentado a rede (deslocamento de fase). Uma alternativa para se lidar com esses problemas é sucintamente descrita a seguir.

**Figura 5.8: Exemplos de padrões cíclicos com vários ciclos, amplitudes, ruídos e deslocamentos de fase.**



A metodologia geral para o reconhecimento de vários tipos de padrões de CEP provou ser eficiente para os padrões cíclicos de períodos conhecidos adotados na tabela 5.5. Contudo, para períodos desconhecidos, como era esperado, a metodologia apresentou-se falha. Sendo assim, em casos onde se tem um certo conhecimento do

processo e a periodicidade pode ser facilmente determinada, a metodologia geral de reconhecimento de padrões deve ser empregada pois além dos padrões cíclicos, outros tipos de padrões podem também ser detectados. Em casos de periodicidade desconhecida as idéias seguintes provaram ser eficientes.

Um pensamento lógico aqui utilizado foi o de que um sistema específico para um determinado tipo de padrão deve ser mais efetivo que um sistema genérico para diversos tipos de padrões.

A detecção de comportamentos cíclicos em cartas de CEP tem sido objeto de estudo usando diversos métodos estatísticos. Sahrman (1979) aplicou o modelamento de séries temporais de Box-Jenkins para detectar padrões cíclicos nas médias de um processo. O maior problema por ele encontrado foi a dificuldade de ajuste dos diversos modelos adotados. Beneke e outros (1998) usaram os recursos da análise espectral e desenvolveram uma carta de controle baseada no periodograma de dados cíclicos. Os resultados dessa carta de controle mostraram ser superiores as técnicas tradicionais. Spurrier e Thombs (1990) modificando a carta de controle espectral, elaboraram uma nova carta espectral envolvendo um maior número de periodicidades. As abordagens da carta de controle espectral são essencialmente modelos de regressão múltipla e o principal procedimento utilizado consiste no teste da hipótese nula de todos os parâmetros da regressão. Se a hipótese nula é rejeitada, existe ao menos uma periodicidade nos dados. Mesmo com o sucesso alcançado com essas metodologias, um grande problema prático aqui associado foi a complexidade de computar as estatísticas de teste.

Usando redes neurais, Hwang (1995) após uma sucessão de experimentos com padrões cíclicos, ofereceu algumas importantes considerações que foram aqui adotadas.

- O conhecimento do processo sobre o qual o reconhecimento de padrões deve ser aplicado é essencial antes de se construir um eficiente sistema. Por exemplo, em certos processos químicos, a periodicidade dos dados pode ser relativamente longa (ex.:50) enquanto em alguns processos mecânicos pode se ter ciclos de períodos

curtos (ex.:8). Assim, se a periodicidade de um processo é conhecida, os parâmetros de treinamento da rede (tabela 5.5) devem ser gerados respeitando tal periodicidade e considerando o tamanho da janela de pontos. Se a periodicidade não é conhecida, uma rede específica deve ser utilizada (em paralelo ou *a priori*) para se testar a atividade cíclica.

- Os valores dos períodos de ciclos para o treinamento da rede neural específica devem ser razoavelmente separados pois ciclos com períodos similares (7 e 8, por exemplo) são praticamente impossíveis de se distinguir, especialmente quando o ruído é adicionado. Um intervalo de 2 a 6 observações é recomendado para a distinção de diversos períodos. Sendo assim, uma rede supervisionada deve ser treinada usando como entrada os padrões cíclicos de diversas periodicidade e como saída as discriminações entre periodicidades.
- O problema da amplitude dos padrões cíclicos como entrada para a rede neural tende a ser reduzido uma vez que o tratamento dos resíduos tende a minimizar a sua importância.
- O deslocamento da janela de pontos auxilia na resolução do problema de fase do ciclo. Ou seja, se um ciclo é apresentado para a rede defasado, com o deslocamento de um certo número de pontos o ciclo estaria em fase e, apesar de uma perda na medida de *performance* do *ARL*, a periodicidade é detectada. O uso de estatísticas dedicadas obtidas a partir dos coeficientes de Fourier (ou *Wavelets*) parecem ser uma promissora alternativa para o melhoramento dessa *performance* mas que tem ainda pouca aplicação prática devido ao tempo computacional envolvido em aplicações em tempo real.

## 5.5 - Experimentos iniciais com a Rede Neural Fuzzy-ARTMAP

Tontini (1995) desenvolveu um sistema baseado em treinamento supervisionado adotando um sistema híbrido com as redes RBF e Fuzzy-ARTMAP. Aqui considerou-se sumamente importante realizar similarmente esses procedimentos no sentido de definir melhor os passos para a pesquisa futura.

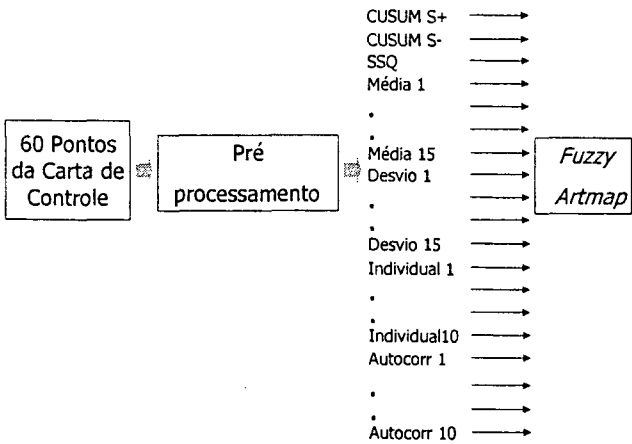
Os experimentos de Tontini foram aqui repetidos com alguma limitação. Em sua primeira parte experimental foi utilizada a rede neural Fuzzy-ARTMAP e os valores dos parâmetros da rede, foram seleccionados a partir da literatura existente. Foi aqui utilizado o programa *The ART Galery* e foram obtidos 1800 padrões não aleatórios de CEP, com 60 observações cada, divididos nas seguintes categorias:

**Tabela 5.8: Banco de dados de treinamento para os estudos iniciais com a rede Fuzzy-ARTMAP.**

Padrões	Amplitude	Número de Padrões
Desvios da média (+, -)	$\pm 1\sigma$ , $\pm 1.5\sigma$ e $\pm 2\sigma$	600
Mistura	$1\sigma$ , $1.5\sigma$ e $2\sigma$	300
Ciclos	$1\sigma$ , $1.5\sigma$ e $2\sigma$ e período 20	300
Sistemáticos	$1\sigma$ , $1.5\sigma$ e $2\sigma$	300
Diminuição da variabilidade	$0.5\sigma$ , $0.6\sigma$ e $0.7\sigma$	300
Total		1800

Aplicados como entrada das redes neurais sem nenhum tipo de pré-processamento, as cartas de controle do banco de dados, como era esperado, não tiveram uma satisfatória taxa de acertos em termos de reconhecimento de padrões. Foram então inseridos algumas simples estatísticas como pré-processamento sobre as cartas de controle que serviram de entrada para a rede Fuzzy-ARTMAP como mostra a figura seguinte.

**Figura 5.9: Processo experimental com as redes neurais evidenciando o pré-processamento dos dados.**



As estatísticas da entrada da rede são resumidas a seguir:

- CUSUM

Os valores máximos das estatísticas da carta de somas acumuladas foi aqui utilizado e obtido pelas expressões:

$$S_t^+ = \sum_{j=1}^t (\bar{X}_{jn} - \mu_0 - K)$$

$$S_t^- = \sum_{j=1}^t (\bar{X}_{jn} - \mu_0 + K)$$

Finalidade: Auxiliar na monitorização do desvio da média.

- SSQ (Soma dos Quadrados dos Resíduos)

$$SSQ_t = \sum_{t=t_1}^{t_2} y_t^2$$

Finalidade: Auxiliar na monitoração da variabilidade do processo e na discriminação entre os padrões de Mistura, Sistemático e Diminuição da Variabilidade.

- Autocorrelação

$$Autocorr_t = \frac{\sum_{i=1}^{t=M-1} Y_t \cdot Y_{t-i}}{\sum_{i=1}^{t=M-1} Y^2_{t-i}}$$

- Médias e Dispersões

Seguindo a orientação de Guo & Dooley (1992), nos moldes da figura 5.4 os 60 pontos das cartas de controle são subdivididos em 15 faixas menores contendo 4 pontos por faixa onde são calculadas as médias e desvios padrões.

Finalidade: Ajudar na identificação de padrões como mistura e sistemático. Os padrões aqui estudados tem uma grande amplitude e podem ocasionar um ponto fora de controle muito antes das estatísticas anteriores terem informação suficiente para sinalizar que tipo de padrão está ocorrendo.

- Pontos Individuais

Os últimos 10 pontos individuais das cartas de controle estão, estreitamente relacionados com os padrões que se quer identificar devido sua forma de inserção nos moldes da figura 5.7.

Finalidade: Ajudar na identificação dos padrões de Mistura e Sistemático

A escolha feita pela rede Fuzzy-ARTMAP como passo inicial de experimentação, em detrimento da escolha da rede *Multilayer Perceptron* treinada por *Backpropagation* procura dar continuidade aos trabalhos de Guo e Dooley (1992), Hwarng e Hubele (1993) e Tontini (1995). A rede treinada por *Backpropagation* (em uma de suas versões) foi já testada nos trabalhos de Cheng (1997) e seus resultados apesar de promissores, foram rapidamente iguados. Além disso, o longo tempo de treinamento e a dificuldade de determinação do número de camadas intermediárias e do número de neurônios nessas camadas causam inúmeras dificuldades para a sua aplicação na automatização de um processo em termos práticos.

#### *Uma nota sobre a rede Fuzzy-ARTMAP*

A operação da rede Fuzzy-ARTMAP está bem apresentada em Carpenter (1995). A teoria de Ressonância Adaptativa, ou ART, foi introduzida como uma teoria sobre o processamento cognitivo de informações no cérebro humano. Essa teoria levou ao desenvolvimento de uma série de modelos de redes neurais capazes de um aprendizado não supervisionado para classificação de padrões em tempo real. Os modelos nessa família compreendem: a rede ART1, que pode aprender a categorizar padrões de entrada binários apresentados em ordem arbitrária; a rede ART2, que pode aprender a categorizar padrões de entrada analógicos ou binários; e a rede ART3, que pode fazer uma busca paralela, ou teste de hipóteses, em códigos com reconhecimento distribuído.


A rede ART1 foi usada no projeto de uma rede com arquitetura hierárquica chamada ARTMAP que tem aprendizado instantâneo, estabelecendo uma associação entre padrões binários de entrada com binários de saída. A rede Fuzzy-ART é uma generalização da rede ART1 para torná-la capaz de reconhecer padrões binários e analógicos, sendo muito mais simples que a ART2.



O desenvolvimento da rede Fuzzy-ARTMAP permitiu a adaptação da rede ARTMAP para a utilização de padrões analógicos tanto na entrada como na saída. A rede Fuzzy-ARTMAP é uma generalização da rede binária ARTMAP. Ela é capaz de um aprendizado supervisionado incremental, atualizando-se durante a operação sem “esquecer” o que já aprendeu anteriormente. Ela também pode ser empregada para classificação e/ou associação de padrões binários e/ou analógicos de entrada e saída com dimensão arbitrária.

A rede Fuzzy-ARTMAP incorpora dois módulos Fuzzy-ART: ARTa e ARTb, conectados através de um módulo inter-ART, Fab, chamado Módulo de Ligação (*map field*) conforme mostra a figura 5.10.

**Figura 5.10: Estrutura da rede Fuzzy-ARTMAP.**



Os módulos ARTa e ARTb funcionam da mesma maneira que a rede Fuzzy-ART, exceto pela interação com o módulo de ligação. O módulo de ligação é usado para fazer associações preditivas entre categorias nas redes ARTa e ARTb e para executar a pesquisa de similaridade, onde o nível de vigilância ( $\rho_a$ ) do módulo ARTa aumenta em resposta a um erro de previsão no módulo ARTb. A pesquisa de similaridade reconhece a estrutura de uma categoria de tal maneira que o erro de previsão não será repetido em apresentações subsequentes da mesma entrada.

### *The ART Gallery*

Os dados originais gerados pelas equações descritas no anexo A são aqui submetidos a uma transformação linear no sentido de normalizá-los no intervalo [0,1]. Os dados foram apresentados para a rede neural no seguinte formato:

1800, 1400, etc...	Número de padrões para treinamento ;
53	Número de entradas para a rede neural (Foram usadas também entradas sem pré-processamento, com menos pontos, etc...);
02	Parâmetro do programa: tipo de entrada (2 para Fuzzy-ART);
7	Número de saídas para a rede neural (6 padrões +normal);
1	Parâmetro do programa: tipo de saída (1 para ART1).

Assim, as entradas analógicas da rede Fuzzy-ART são do tipo:

0.13

0.22

.....

0.10

e as entradas da rede ART1 (ou respostas dos padrões de classificação) obedecem ao seguinte formato (o valor 1 no vetor representa um dos padrões não aleatórios que se quer identificar):

0 0 0 0 0 1 0 representando por exemplo "Mistura".

O algoritmo aqui utilizado foi codificado por Lars Liden (laliden@cns.bu.edu) em 1995 sob a forma de um conjunto de subrotinas denominadas de *The ART Gallery*, que rodam em plataforma Windows e UNIX. Suportando tanto aprendizagem supervisionada como não-supervisionada, o pacote computacional emprega dois tipos diferentes de redes: ART, para o modo não supervisionado, e ARTMAP para o modo supervisionado. Ambos os modos de redes são construídos de componentes ARTs, os quais podem tomar diferentes formas, inclusive ART1 e Fuzzy-ART.

- *Rede ART*

Resumidamente, podemos dizer que uma rede neural do tipo ART é usada para aprendizagem não-supervisionada. Ela consiste de uma componente que tem como entrada um conjunto de padrões a serem agrupados. A rede aprende a agrupar as entradas em categorias as quais podem ser modificadas com novos padrões de entrada (tal característica denomina-se plasticidade). Para o *The ART Gallery* os componentes da rede ART podem ser do tipo ART1, para entradas binárias de padrões e do tipo Fuzzy-ART para entradas analógicas de padrões.

- *Rede ARTMAP*

A rede ARTMAP é utilizada para aprendizagem supervisionada. Ela consiste de dois componentes ARTs, uma entrada denominada ARTa e uma saída, chamada ARTb, que tem os padrões e seus resultados de classificação como parâmetros de entrada. Os dois componentes são ligadas pelo módulo de ligação.

O componente ARTa agrupa padrões de entrada baseado na sua relação (*feedback*) com o módulo de ligação. ARTa pode ser do tipo ART1 para entradas binárias e Fuzzy-ART para entradas analógicas.

O componente ARTb agrupa padrões de saída em categorias e envia um conjunto de ativação para o módulo de ligação. ARTb pode ser do tipo ART1, para saídas binárias, Fuzzy-ART para saídas analógicas, ou ainda do tipo *NONE*. Nesse último tipo as saídas são diretamente enviadas para o módulo de ligação ao invés de serem agrupadas por ARTb.

É claro que as entradas de ARTb são as corretas respostas dos padrões de classificação da rede neural.

Cada componente ART usa os dados de entrada e saída em sua forma original, dentro do intervalo [0-1], ou, de uma forma alternativa, acrescentando o conjunto complementar dos dados. Nesse segundo caso, o número de entradas para o componente ART é obviamente o dobro de entradas do padrão de classificação da rede, onde uma cópia “negativa” da entrada é apresentada para a rede. Assim, se um conjunto de

padrões de entrada for, por exemplo, o vetor  $0.2, 0.3, 0.5, 0.7$ , então a rede terá, sob a forma de complemento o vetor  $0.2, 0.3, 0.5, 0.7$  e também  $0.8, 0.7, 0.5, 0.3$ .

O treinamento da rede ocorre até que um aprendizado estável tenha sido obtido ou o número máximo de épocas de treinamento seja atingido. O desempenho da rede pode ser verificado através das informações sobre o número de entradas corretamente e incorretamente classificadas além do número de padrões não classificados em ARTa e ARTb.

Para o problema em questão o seguinte protocolo dentro do programa *The ART Gallery* pode ser visto na figura 5.11. Os resultados alcançados com a rede Fuzzy-ARTMAP apesar de promissores não foram conclusivos devido a dificuldade de avaliação das medidas de desempenho. Toda a análise envolvendo o cálculo do *ARL* e medidas derivadas não foi possível devido as limitações intrínsecas do programa *The ART Gallery*, não disponibilizando um código computacional compilável.

**Figura 5.11: Tela de trabalho do programa *The ART Gallery* com os parâmetros da rede Fuzzy-ARTMAP para a classificação dos padrões dos gráficos de controle.**

The screenshot displays the 'The ART Gallery' software interface, which is organized into several functional panels:

- Network Panel:** Includes a 'Network:' section with radio buttons for 'Art' and 'ArtMap' (selected), a 'READY' button, and a 'Fuzzy Art' checkbox (checked).
- ArtA Configuration:** Shows '229 Nodes', '6 Inputs', and 'Compliment' checked. It also includes 'ArtA Winner: 82' and an 'Input' table.
- ArtB Configuration:** Shows '7 Nodes', '14 Outputs', and 'Compliment' checked. It includes 'ArtB Winner: 2' and an 'Output' table.
- Pattern Set Panel:** Displays 'Patterns: 4061', 'Inputs: 3', and 'Outputs: 7'. It has radio buttons for 'Binary' and 'Analog' (selected).
- Map Panel:** Features a 'Map' visualization area and a 'Pattern Number' input field set to '2'.
- ART A and ART B Performance:** Each has a 'Vigilance' input field (set to '9') and a 'Recoding Rate' input field (set to '1').
- Mapfield Panel:** Includes a 'Mapfield' input field (set to '1') and a 'Vigilance' input field (set to '1').
- Control Panel:** Contains buttons for 'Load Net', 'Train Net', 'Make Net', 'Clear Net', 'About', 'Save Net', 'Test Net', 'Load Set', 'Clear Set', 'Make Set', 'Save Set', and 'Quit'.

A tela de saída do programa *The ART Gallery*, mostra os melhores resultados alcançados nesse problema de reconhecimento de padrões utilizando o protocolo da figura 5.11. Tais resultados são surpreendentes se comparados ao reconhecimento feito por um especialista. Imagine a complexidade e o tempo para um especialista investigar padrões variantes com o tempo em 4045 cartas de controle!

**Figura 5.12: Resultados do *The ART Gallery* para o problema de identificação.**

Test Results		
Correct	3795	93,82%
Incorrect	250	6,18%
ArtA No Answer	0	0,00%
ArtB No Answer	0	0,00%
TOTAL	4045	OK

O tempo de processamento, extremamente curto em relação ao treinamento por *Backpropagation*, mostrou ser uma importante vantagem nesse tipo de metodologia, ainda mais quando consideramos que a plasticidade é uma das características desse tipo de rede.

Algumas vantagens da rede Fuzzy-ARTMAP devem ser enfatizadas pois atendem a uma gama de processos que lidam com reconhecimento de padrões, principalmente aqueles que tratam com sistemas automatizados de manufatura, uma grande tendência dos processos atuais.

- Adaptar-se a mudanças no processo e *aprender* com problemas e exemplos ocorridos durante sua operação, mesmo que esses exemplos não tenham sido estruturados;
- Tratar relações não lineares;
- Tratar problemas difusos, comuns de se encontrar na vida real.

## 5.6 Experimentos com a Função de Base Radial

A finalidade dessa seção é apresentar a especificação e avaliação da RN com Função de Base Radial (*Radial Basis Function Network* –RBFN) usada para classificar os padrões de CEP e para a aplicação descrita no capítulo 6.

Uma RBFN é uma arquitetura de RN *feedforward* que usa uma camada interna simples de neurônios localmente sintonizados (*locally-tuned*) para executar tarefas de classificação e aproximação de funções de valores reais (*real-valued*) (Moody e Darken, 1989).


A representação dos neurônios da camada interna são radialmente simétricos consistindo de um centro, uma medida de largura e uma função de ativação. A RBFN tem sido proposta por Broomhead e Lowe (1988) e Moody e Darken (1989) como uma arquitetura alternativa de rede *feedforward* para o aprendizado do mapeamento entre entrada e saída. As RBFNs tem sido aplicadas a uma grande variedade de problemas, contudo em uma quantidade bastante inferior em relação ao uso de *Backpropagation* (Haykin, 1994).

Uma RBFN tem basicamente três camadas. A primeira camada consiste do vetor de entrada o qual é transferido para os neurônios da camada interna (segunda camada ou camada de padrões). As ativações dos neurônios são transferidos para os nós de saída da terceira camada (camada de saída). A camada de padrões consiste de neurônios com campos localmente receptivos. Ao invés de avaliar um somatório de entradas, tais neurônios computam a proximidade das entradas em relação aos centros desses campos (Wong, 1991). As conexões da camada de padrões com a camada de saída são ponderadas da maneira usual das redes neurais e as funções de ativações dos neurônios de saída podem ser uma soma linear dos neurônios ou também utilizar uma função de ativação não linear (sigmóide ou tangente). Assim, uma RBFN toma uma entrada de dimensão  $I$  e calcula  $K$  vetores de saída explorando a camada de padrões da rede (Lowe, 1989). A transformação do espaço de entrada para o espaço da camada de

padrões é não linear, e a transformação do espaço da camada de padrões para a camada de saída pode ser linear ou não linear (Haykin, 1994).

Cada neurônio da camada de padrões tem seu próprio centróide (centro de dimensão  $n$ ). Para cada entrada ele computa a distância entre o vetor de entrada e seu centro. A saída desse neurônio é uma função não linear dessa distância. Assim, cada neurônio computa uma saída que depende de uma função radial simétrica tendo uma maior saída gerada quando a entrada está mais próxima do centro do neurônio da camada de padrões (Park e Sandberg, 1991). As RBFNs utilizam a superposição de regiões formadas por funções simples para criar regiões de decisões complexas. Isso habilita a RBFN a generalizar extremamente bem (Mak, Allen, e Sexton, 1993). Em contraste com a rede *Backpropagation*, que usa um hiperplano para classificar padrões em diferentes regiões, as RBFNs usam modelos localizados do espaço de entrada. Esse método localizado particiona melhor as características do espaço do que as fronteiras do hiperplano. A figura a seguinte explica essa diferença (Bishop, 1995) para casos bidimensionais.

**Figura 5.13: Característica dos espaços das redes *Backpropagation* e RBFN.**




Tem sido provado que a RBFN pode aproximar arbitrariamente qualquer função contínua multivariada desde que a função de ativação dos neurônios da camada de padrões seja contínua e um número suficiente de neurônios sejam utilizados (Park e Sandberg, 1991). Isso provê uma base analítica para o projeto das RNs usando Funções de Base Radial.

## Arquitetura da Rede

O desenvolvimento da arquitetura da RBFN compreende basicamente 5 considerações: (1) a direção do fluxo de informação; (2) esquema de interconexão das camadas; (3) a camada de entrada; (4) camada de saída ( de classificação), e (5)camada oculta (de padrões). A figura 5.13 ilustra um exemplo de RBFN.

**Figura 5.14: Arquitetura da RBFN.**



Em suma, tal arquitetura é resumida a seguir:

*Direção do fluxo da informação:* a RBFN é considerada uma rede *feedforward* multicamada, sendo portanto unidirecional.

*Esquema de Interconexão das camadas:* A RBFN é considerada totalmente conectada. A única exceção é que o *bias* é somente conectado aos neurônios de saída e não aos neurônios da camada de padrões. Os pesos entre a camada de padrões e a camada de saída são classificados para executar a tarefa de classificação.

*Camada de Entrada:* A estrutura da camada de entrada é determinada pelo domínio do problema. O número de neurônios aqui considerados correspondem aos pontos de uma carta de CEP (após o processamento autoregressivo usando séries temporais).



*Camada de saída (de classificação):* Tal camada é também determinada pelo domínio do problema. O número de neurônios aqui corresponde ao número de categorias de classificação do problema; nesse caso, o número de padrões das cartas de CEP.

*Camada Oculta (de padrões):* A RBFN consiste de somente uma camada oculta. Tal camada é totalmente conectada à entrada e os neurônios de entrada passam os seus valores aos neurônios da camada de padrões inalterados, ou seja, sem ajustamento dos pesos. Esse vetor de entrada é então processado usando os centróides da camada de padrões através de um somatório e de uma função de ativação.

Cada neurônio da camada de padrões representa uma função de base radial, (ou seja, uma função com decisão hiperesférica). Essas funções dividem o espaço de entrada  $R^n$  (com  $n$  número de padrões) em um número de hiperesferas iguais ao número de neurônios da camada de padrões (Cios e outros, 1991).

As fronteiras de classificação são então modeladas pelos neurônios da camada de padrões (Renals e Rohwer, 1989). Isso implica que um simples neurônio não pode desenvolver uma tarefa de classificação em muitas categorias. Na verdade, deve-se ter no mínimo um número de neurônios igual ao número de categorias a serem classificadas. Contudo, poucos neurônios podem não ser suficientes para modelar adequadamente as fronteiras de classificação e assim pode-se ter muito mais neurônios do que as categorias de classificação. Em caso de se ter um número elevado de neurônios as fronteiras de classificação podem ser super influenciadas pelos exemplos de treinamento.

Isso significa que esse número de neurônios pode estar num intervalo entre o número de categorias a serem classificadas e o número de vetores de treinamento. Entretanto, a complexidade da rede aumenta com o aumento do número de neurônios da camada de padrões. Isso pode fazer com que o uso de um grande número de neurônios conduza a resultados irrealísticos (por exemplo, decorando o número de exemplos de

treinamento). Em aplicações práticas é freqüentemente desejável se ter um número menor de neurônios, tendo com isso menos centros (Billings e Zheng, 1995). Uma rede composta de muitos neurônios pode levar a um excelente desempenho a um conjunto de treinamento, mas uma rede menor pode generalizar melhor para exemplos não vistos no treinamento. Markhan e Ragsdale (1995) sugerem que esse número de neurônios deveria ser o número de entradas mais 2. Lippman (1987) sugere que se pode ter tipicamente mais do que 3 vezes o número de entradas. Pao (1989) sugere o dobro do número de entradas. Billings e Zheng (1995) usaram algoritmos genéticos na tentativa de determinar o número ótimo de neurônios mas um método experimental (considerando sistematicamente a tentativa e erro) tem sido o método predominante (Fredrickson e Tarassenko, 1995). Isso foi também utilizado nesse trabalho.

### Neurodinâmica da Rede

A camada de padrões consiste de um conjunto de funções de base radial. Associada com cada neurônio dessa camada está um centro  $c_j$ . Cada neurônio calcula a distância entre o vetor de entrada e o centro e passa essa distância para a função de ativação de base radial. Tal distância é calculada por uma função somatório.

Algumas definições são a seguir apresentadas:

*Função Somatório:* A mais popular e tipicamente utilizada dessas funções desenvolve a métrica da distância Euclideana (Musavi e outros). Uma vez calculada, ela se torna o argumento da função de base radial.

*Função de Base Radial:* As típicas funções não lineares de base radial são:

(1) função *thin-plate-spline*:

$$\Phi(v) = v^2 \log(v)$$

(2) função Gaussiana:

$$\Phi(v) = \exp\left(-\frac{v^2}{\beta^2}\right)$$

(3) função multiquadrática:

$$\Phi(v) = (v^2 + \beta^2)^{1/2}$$

(4) função inversa multiquadrática:

$$\Phi(v) = (v^2 + \beta^2)^{-1/2}$$

onde  $v$  é a distância do vetor de entrada  $x$  ao centro da função de base radial  $c$  e  $\beta$  é a largura da função (Chen, Cowan, e Grant, 1991).

A função Gaussiana é a função de ativação mais comumente utilizada e tem sido considerada uma poderosa função no aprendizado do complexo mapeamento entre entradas e saídas (Wong, 1991). A escolha da função de ativação entre as quatro funções acima citadas, entretanto, não tem mostrado ser um ponto crítico no desempenho da RBFN (Lowe, 1989).

As funções Gaussianas são especificadas por um centro e uma largura. A ativação é uma função da proximidade do vetor de entrada com o vetor de centros (Fredrickson e Tarassenko, 1995) e é definido como:

$$\Phi_j(\|x - c_j\|) = \exp\left(-\frac{1}{2\sigma_j^2}(x - c_j)^T(x - c_j)\right)$$

ou equivalentemente

$$\Phi_j(\|x - c_j\|) = \exp\left(-\frac{1}{2\sigma_j^2}\|x - c_j\|^2\right) \quad (5.1)$$

onde

$\Phi_j$  é a saída do centro  $j$ ,  $x$  é o vetor de entrada,  $c_j$  é o centro  $j$ ,  $\|\cdot\|$  denota a distância Euclidiana, e  $\sigma_j$  é a largura da função que controla a influência da  $j$ -ésima função Gaussiana sobre uma pequena região com centro  $c_j$ .

As funções Gaussianas evitam que as RBFNs produzam um valor alto de saída para observações muito distantes de seus centros. Isso ajuda a reduzir a extrapolação do erro que ocorre quando os dados de teste caem além do intervalo do conjunto de treinamento. Pode ser visto a partir da equação (5.1) que a função Gaussiana tem o seu valor máximo de 1 quando  $\|x - c_j\|$  é igual a zero e tem valor decrescente quando  $\|x - c_j\|$  tende a infinito.

### Operação da Rede

As RNs *feedforward* podem ser vistas como sistemas que executam uma operação de aproximação de curvas em um espaço de alta dimensão. O aprendizado, então, representa o processo de produção da melhor aproximação de uma hipersuperfície a um conjunto finito de dados (isto é, o conjunto de treinamento). A generalização é equivalente a interpolação do conjunto de teste nessa hipersuperfície. A RBFN está então executando uma tarefa de interpolação quando ela classifica um conjunto não visto de padrões (Haykin, 1994).

No projeto original de uma RBFN (Broomhead e Lowe, 1988; Moody e Darken, 1989) são definidos os centros das funções de base radial para cada um dos exemplos de treinamento. Nesse método, são então necessários um número de centros igual ao número de exemplos de conjunto de treinamento.

Vale aqui lembrar que o principal objetivo da operação da rede é aproximar uma função do mapeamento entre entrada e saída (Komo, Chang, e Ko, 1994) e que a camada de padrões consiste de funções de ativações não lineares; os valores da camada de saída poderiam ser o resultado do mapeamento linear das ativações da camada de padrões para a camada de saída. Assim, o uso da RBFN consiste na determinação de uma função  $f$  que tem a seguinte forma:

$$f(x) = w_{k0} + \sum_{j=1}^N w_{kj} \Phi_j(\|x - c_j\|) \quad (5.2)$$

onde  $f(x)$  é o vetor de saída,  $w_{ko}$  representa o bias da saída  $k$ ,  $N$  é o número de neurônios da camada de padrões (número de centros das funções de base radial) o qual é igual ao número de exemplos de treinamento (nessa abordagem inicial);  $w_{kj}$  é o peso entre o centro  $j$  e o neurônio de saída  $k$ ,  $\Phi_j$  é a saída do neurônio padrão  $j$ ,  $x$  é o vetor de saída a ser classificado,  $c_j$  é o centro da função, e  $\|\cdot\|$  representa a distância Euclidiana. O *bias* pode alternativamente ser definido com o valor de  $-1$ , com um peso positivo representando o limiar (Zurada, 1992) e assim a equação (5.2) pode ser escrita como:

$$f(x) = \sum_{j=0}^N w_{kj} \Phi_j(\|x - c_j\|) \quad (5.3)$$

Para se encontrar os coeficientes  $w_{kj}$ , pode-se simplesmente resolver a equação 5.3 onde os centros e os exemplos de treinamento são fornecidos (Mak, Allen, e Sexton, 1993) pois existem exatamente  $N$  equações com um mesmo número de incógnitas (os pesos). Isso leva ao seguinte sistema linear:

$$Aw = d$$

onde  $w$  é o desconhecido vetor de pesos,  $d$  é o vetor de saídas desejada e  $A$ , a matriz de interpolação, é uma matriz  $N$  (exemplos de treinamento) por  $N$  (centros) definida como  $\Phi_{ij} = \Phi(\|x_i - c_j\|)$  para cada exemplo de treinamento  $x_i$ . Em outras palavras, cada coluna de  $A$  é um vetor base correspondente a um centro particular. O sistema linear pode ser resolvido se  $A^{-1}$  existe por meio de:

$$w = A^{-1}d \quad (5.4)$$

Uma condição suficiente e necessária para a existência de uma solução única para os pesos é a invertibilidade da matriz  $A$  (Sherstinsky e Picard, 1996).

Assim o treinamento de uma RBFN pode ser vista como um problema de interpolação resolvido por inversão de matrizes. Mas essa aproximação freqüentemente causa problemas numéricos pois as matrizes envolvidas são tipicamente largas

(Sherstinsky e Picard, 1996) e o uso direto de inversão de matrizes para se encontrar os pesos as vezes torna-se impraticável. Portanto, definindo-se os centros das funções de base radial nos moldes do método acima, é produzida uma rede cuja implementação não é satisfatória para um grande número de casos. Existem dois métodos disponíveis para resolver esse problema: ou a complexidade da rede deve ser reduzida para aproximar a solução acima (Haykin, 1994) ou outro método deve ser utilizado para obter os pesos entre a camada de padrões e a camada de saída.

O primeiro método envolve a determinação de uma solução em uma dimensão reduzida do espaço da camada de padrões que aproxima a solução obtida pela equação (5.4). Esse método de aproximação executa a redução do número de centros da função de base radial. Uma matriz  $A^\wedge$  é obtida selecionando um subconjunto de  $M$  exemplos de treinamento formando uma matriz  $N$  (exemplos de treinamento) por  $M$  (centros). O produto  $(A^\wedge{}^T A^\wedge)$  é então uma matriz inversível e uma base no espaço de dimensão  $M$ . Usando esse resultado, pode ser formulado e resolvido uma aproximação para esse sistema linear (Sherstinsky e Picard, 1996).

Dado  $A^\wedge$  e  $d$ , pode-se encontrar o vetor de pesos ótimo,  $w^*$ , minimizando o erro quadrático. Em outras palavras,  $w^*$  é obtido minimizando o erro quadrático definido pela seguinte expressão:

$$E = \sum_{p=1}^N \left[ d(x_p) - \sum_{j=0}^M w_{kj}^* \Phi_j(\|x_p - c_j\|) \right]^2$$

onde  $d(x_p)$  é a saída desejada para o vetor de entradas  $x_p$  e  $N$  é o número total de exemplos de treinamento. Nesse caso, os centros não são requeridos a coincidir com os “centros” dos exemplos de treinamento, podendo ser reduzidos a um conjunto menor. Os dados de treinamento podem agora ser aproximados usando:

$$A^\wedge w^* = d$$

A solução ótima dos mínimos quadrados é dada por

$$w^* = A^+ d$$

onde  $A^+$  é a pseudo inversa de  $A$  e é igual a:

$$A^+ = (A^T A)^{-1} A^T$$

Se a RBFN com um subconjunto de centros aproxima adequadamente o conjunto de treinamento, o método é computacionalmente eficiente para a determinação do vetor de pesos,  $w^*$ . Usando esse método tais pesos são obtidos pelo uso da pseudo inversa de  $A$ .

A outra aproximação para a determinação dos pesos, em contraste com a inversão de matrizes (ou pseudo inversão), é usar a técnica de aprendizagem supervisionada. Um candidato natural é a aproximação de correção de erros convenientemente implementada usando métodos de gradiente descendente (Fredrickson e Tarassenko, 1995).

A discussão acima claramente indica que uma grande parte do aprendizado da rede consiste na determinação dos pesos entre a camada de padrões e a camada de saída baseada nos exemplos de treinamento. Tal discussão também ilustra que é possível obter os pesos mesmo se o número de neurônios da camada de padrões é menor do que o número de exemplos de treinamento. Contudo, mesmo tentando obter tais pesos reduzindo o número de centros, usando pseudo inversão, a complexidade da rede ainda aumenta quando tem-se um grande número de centros (inferior ao número de observações de treinamento). Além disso, quando o neurônio de saída possui uma função não linear (como por exemplo sigmóide ou tangente hiperbólica), não é possível usar uma aproximação envolvendo cálculos diretos para a obtenção dos pesos.

Wong (1991) sugere que em aplicações práticas é freqüentemente desejável usar um aprendizado por gradiente descendente para a obtenção dos pesos. Na utilização do método de gradiente descendente, contudo, uma boa investigação deve ser feita em termos de critérios de convergência, uma vez que para o treinamento de uma rede

considerando um erro bem pequeno pode-se não conseguir um desempenho ótimo de classificação. Nesse caso, a rede decora o conjunto de dados de treinamento para obter um mínimo erro, mas perde o seu poder de generalização para o conjunto de testes (Cheng e Titterington, 1994). Mesmo que haja uma forte correlação entre a minimização do erro para o conjunto de treinamento e a maximização do desempenho da rede, não é garantido que um mínimo erro na solução irá produzir o melhor resultado de classificação do conjunto de testes (Lowe, 1989).

Haykin (1994) sugere um outro critério de convergência baseado na habilidade da rede em generalizar. Ele sugere o teste da rede em termos de seu desempenho de generalização após cada interação (ou algum número definido de interações), terminando o treinamento da rede quando o desempenho da rede for adequado ou estiver no máximo. Em outras palavras, uma estratégia mais efetiva de treinamento poderia ser treinar a rede baseado em uma função objetivo que maximize o desempenho de um conjunto de teste.

O método acima foi adotado nessa pesquisa. Dessa forma, a RBFN interativamente adiciona a ela um neurônio por vez, até que sejam atingidos um erro quadrado mínimo (*Sum-Squared Error* - SSE) ou um máximo número de neurônios. A função usada tem assim os seguintes parâmetros:

$$RBFN = \text{function}(P, T, Goal, Spread),$$

onde  $P$  e  $T$  são os valores de entrada e saída da rede usadas no treinamento,  $Goal$  contém as informações do erro mínimo (SSE) que se deseja atingir e o número máximo de neurônios a serem utilizados.  $Spread$  representa a largura da função de base radial.

### Treinamento da Camada de Padrões

O desempenho da RBFN depende criticamente dos centros da função de base radial e uma questão chave é como determinar apropriadamente esses centros (Chen, Cowan, e Grant, 1991). Existem vários meios de se escolher a localização dos centros



dos neurônios da camada de padrões (isto é, o centro da função de base radial) em uma RBFN. Os principais métodos são: (1) um centro para cada exemplo de treinamento; (2) seleção aleatória dos centros a partir do conjunto de treinamento; (3) um procedimento de aprendizagem supervisionada; e (4) um método não supervisionado (*clustering*).

A primeira aproximação é selecionar um centro para cada exemplo de treinamento (Yegnanarayana, Chouhan, e Sekhar, 1992). É simples definir uma função Gaussiana para cada exemplo de treinamento mas isso torna-se impraticável quando existe um grande número de exemplos pois essa aproximação freqüentemente causa problemas numéricos devido aos tamanhos das matrizes envolvidas (Sherstinsky e Picard, 1996). Além disso, quando o número de centros da função de base radial da camada de padrões é muito grande, a rede pode aproximar o ruído dos dados de treinamento e prejudicar o desempenho da generalização (Broomhead e Lowe, 1988). Esses problemas levam a alternativas que reduzem o número de centros da função de base radial, de tal forma que em aplicações práticas o número de centros é usualmente menor do que o número de exemplos de treinamento (Haykin, 1994).

Um método comumente utilizado para selecionar tais centros é escolher aleatoriamente algum subconjunto dos exemplos de treinamento (Chen, Cowan, e Grant, 1991). Lowe (1989) cita que isso é uma maneira coerente se as amostras de treinamento são distribuídas de uma maneira representativa. Chen, Cowan e Grant, (1991) acreditam que esse método não é satisfatório e apontam as seguintes falhas. Primeiro, o conjunto de treinamento pode não ser igualmente distribuído sobre o espaço de entrada. A concentração das amostras de treinamento em algumas regiões do espaço de entrada podem ser esparsas e a seleção randômica dos centros pode resultar em algumas regiões tendo poucos ou nenhum exemplo. Isso significa que os centros selecionados podem não representar adequadamente o domínio de entrada. Um segundo ponto é que a saída desejada do mapeamento da função comumente terá uma variação diferencial em várias regiões do espaço. Isso implica na necessidade de mais centros nas regiões de rápida variação e menos centros naquelas regiões de poucas variações. Uma seleção randômica de centros não facilita a resolução desse problema.

No caso de neurônios com saídas lineares, um procedimento de aprendizagem denominado Mínimos Quadrados Ortogonais (*Orthogonal Least Square – OLS*) pode ser usado para selecionar um conjunto adequado de centros a partir do conjunto de treinamento (Chen, Cowan, e Grant, 1991). O método OLS envolve a transformação do conjunto de centros em um conjunto de vetores ortogonais constituindo uma base para o espaço de entradas. Com isso torna-se possível calcular a contribuição individual de cada uma dessas bases para a saída desejada. Chen, Cowan e Grant (1991) usaram OLS em um procedimento de regressão para selecionar um subconjunto de centros a partir do conjunto de treinamento. A cada passo da regressão o incremento da variância explicada da saída desejada é maximizado. Os autores também mostraram que a seleção dos centros usando OLS é superior a seleção aleatória de centros. Como desvantagem, Sherstinsky e Picard (1996) mostraram que o método OLS não é efetivo se a camada de saída possui neurônios com saídas não lineares.

Uma estratégia efetiva de localização de centros consiste no uso de técnicas não-supervisionadas (Haykin, 1993). Usando essa estratégia os centros podem ser determinados por técnicas como o K-Means (Fredrickson e Tarassenko, 1995). Esse método pode ser utilizado para agrupar os exemplos de treinamento com o resultado desses grupos (clusters) sendo utilizados como centros da camada de padrões.

Para o problema em questão o uso de OLS torna-se razoavelmente mais simples em função do seguinte e importante aspecto: o número de neurônios da camada de padrões é automaticamente identificado com esse método. Tal aspecto consiste na principal desvantagem do método K-means que acarreta numa grande quantidade de experimentos (onde principalmente são utilizadas as técnicas de Projetos de Experimentos) para a determinação do número de centros. O método OLS, usado nessa pesquisa, encontra-se sumarizado no anexo B.

Menos utilizados estão ainda alguns outros métodos que prometem ser excelentes alternativas abordando aproximações sucessivas, Fuzzy k-means, etc....que deverão ser utilizados em melhoramentos futuros.

### Determinação das larguras da função de Base Radial

Uma vez que o número de neurônios da camada de padrões são determinados, a largura de cada centro pode ser determinada. Tal largura é uma distância escalar que determina um valor no espaço de entradas no qual o neurônio da camada de padrões terá uma influência significativa (Leonard e Kramer, 1991). Tal largura controla também a quantidade de sobreposição entre os centros assim como a generalização da rede. Pequenos valores resultam em uma mudança muito rápida no mapeamento entre a entrada e a saída enquanto grandes valores resultam em uma função bastante suavizada. (Musavi e outros, 1992).

Uma apropriada largura de uma função de base radial pode ser determinada pelo uso da heurística dos  $P$ -vizinhos mais próximos (Fredrickson e Tarassenko, 1995) e é definida por:

$$\sigma_j = \sqrt{\frac{1}{p} \sum_{j=1}^p \|x_j - c_j\|^2}$$

onde  $x_i$  são os  $P$ -vizinhos mais próximos do centro  $c_i$ .

Essa diferença de larguras de centros resulta numa sobreposição entre cada centro e seus vizinhos formando uma interpolação suave sobre aquelas regiões do espaço de entradas que eles representam (Moody e Darken, 1989). Para fazer isso, cada neurônio padrão deve ativar no mínimo um outro neurônio padrão. Isso significa que a largura do neurônio padrão deve ser maior do que a sua distância ao centro do outro nó padrão mais próximo. A largura, entretanto deveria ser mantida a um valor mínimo para sustentar a influência do neurônio padrão e prevenir altos valores de ativação distantes dos exemplos de treinamento que eles representam (Leonard e Kramer, 1991).

Nessa pesquisa, devido ao tipo de entrada residual das cartas de controle, com um aproximado nível estatístico de amplitude, a largura da função de base radial foi mantida constante (com diversos níveis) nos experimentos realizados. Uma pesquisa futura contudo é desejável abordando novos métodos para o cálculo de tal largura .

## Vantagens e Desvantagens da RBFN

As RBFNs tem muitas vantagens. Seu treinamento é bastante rápido pois a localização dos centros pode ser determinada usando aprendizagem supervisionada e essa representação local assegura que somente uns poucos neurônios da camadas de padrões respondem a uma dada entrada. Essa resposta local da camada de padrões é muito importante. Para qualquer padrão a ser classificado, somente uma fração dos neurônios dessa camada com centros próximos ao vetor de entrada irão responder com ativações que diferem significativamente de zero (Moody e Darken, 1989). Existe também uma redução no tempo computacional requerido pelo aprendizado supervisionado desde que somente uma camada de pesos precisa ser atualizada.

As RBFNs também provêem uma melhor fronteira de decisão do que as redes baseadas em *Backpropagation* pois a sua representação localizada do espaço de entrada resulta em um melhor particionamento do espaço de decisão (Fredrickson e Tarassenko, 1995). Além disso, elas tem a habilidade de reduzir erros de extrapolação e de prover informações para novos padrões no espaço de entrada não cobertos pelos dados de treinamento. As funções de ativações dos neurônios são auto limitantes em regiões que elas formam as quais elas incorporam a informação de distância. Isso facilita a classificação de novos padrões de acordo com a sua proximidade ao conjunto de treinamento. Isso habilita a rede em indicar que um padrão original de entrada está distante do conjunto de treinamento embora ainda efetuando a mais plausível classificação (Leonard e Kramer, 1991). Isso é particularmente atrativo desde que em muitos casos o número de exemplos de treinamento pode ser limitado e todas as categorias de classificação podem não ser representadas. Assim as RBFNs podem estimar o quão próximo um padrão original está do conjunto de treinamento permitindo assim identificar um conjunto de testes que representa uma nova categoria de padrões em função dos pobres resultados obtidos em relação ao conjunto de dados estabelecidos durante o treinamento (Leonard e Kramer, 1991). Essas características habilitam a RBFN a generalizar extremamente bem mesmo em tarefas complicadas e o desempenho da rede não é muito prejudicada pelo não balanceamento das quantidades do conjunto

de treinamento disponível para as diferentes categorias de padrões (Mak, Allen, e Sexton, 1993).

Esse paradigma de rede é assim melhor para uso em aplicações onde os dados de treinamento são esparsos, não balanceados e o número de exemplos de treinamento podem ser limitados e todas as categorias de classificação podem não ser representadas (Leonard e Kramer, 1991). Em resumo, as RBFNs provêem uma excelente aproximação e representam uma técnica robusta para um grande número de problemas tais como modelamento de dados.

As RBFNs tem uma desvantagem potencial: desde que a fase inicial de treinamento é não supervisionada (ou auto organizada) para o agrupamento de centros, existe a possibilidade de perda de algumas informações discriminantes (Haykin, 1994).

## 5.7 Análise de Resultados

Um conjunto extenso de simulações é necessário para se testar a capacidade da rede em detectar os diversos padrões não aleatórios das cartas de controle. Nesse sentido, o algoritmo da rede neural é repetidamente aplicado às seqüências de dados e quando o padrão de interesse é detectado, o *RL* (*run length* - número de pontos até a detecção do padrão não natural) é obtido. Com um número considerável de RLs pode-se ter o cálculo do *ARL*.

Dois tipos de falsos alarmes podem ocorrer na utilização da maioria dos algoritmos que lidam com o reconhecimento dos padrões de CEP. O primeiro resulta quando o algoritmo detecta um padrão não aleatório qualquer quando ele de fato não existe (ou seja, o processo está sobre controle e o algoritmo diz que não está). O segundo é quando o algoritmo detecta um padrão não aleatório mas o padrão detectado não corresponde ao padrão alvo simulado (ou seja, há um erro na identificação do padrão, por exemplo, o algoritmo detecta um ciclo quando de fato há um desvio da média). Esse segundo falso alarme é freqüentemente mais difícil de evitar pois muitos padrões, incluindo ciclos, contém outros tipos de padrões como por exemplo as tendências.

O *ARL* pode ser utilizado como uma boa medida de desempenho para avaliar a questão dos falsos alarmes. Como exemplo, Champ e Woodwal (1987) apresentam o *ARL* para gráficos de Shewhart abordando os falsos alarmes com e sem as regras suplementares (*runs rules*) propostas pela Western Electric. Tontini (1995) amplia essa análise envolvendo os seus resultados. A tabela seguinte apresenta essa análise, desenvolvida para desvios da média.

**Tabela 5.9: *ARL* para Desvios da Média usando vários métodos.**

Desvios da Média	0σ	1.0σ	1.5σ	2.0σ
Shewhart	370.4	43.9	16.2	6.3
Shewhart +Regras	91.75	9.22	5.0	3.13
CUSUM	407.4	10.09	5.99	3.84
Fuzzy ARTMAP	165.9	19.91	9.10	5.36
RBF-Fuzzy ARTMAP	180.1	18.32	9.00	5.92
RBF	190.9	19.33	9.10	5.82

Fonte: Tontini (1995)

Obs.: As cartas de controle nesse caso foram definidas em termos de 60 observações.

O desempenho de um sistema de reconhecimento de padrões é usualmente avaliado por sua capacidade de classificação e generalização. A capacidade de classificação avalia se um sistema treinado tem aprendido a classificar corretamente os dados de um conjunto de treinamento enquanto a capacidade de generalização se refere a habilidade do sistema treinado em classificar corretamente dados similares que não foram vistos antes.

Usualmente, a *performance* de uma carta de controle é medida pelo *ARL*. Uma importante contribuição, proposta por Hwarng e Hubele (1993), usa a expressão abaixo:

$$ARL_{tx} = ARL_t / R_t \qquad (5.5)$$

onde  $R_t$  é a percentagem de padrões no qual o padrão não aleatório alvo foi detectado primeiramente e  $ARL_t$  é o *ARL* para detectar o padrão não aleatório alvo.

O valor de  $ARL_{tx}$  descreve em síntese uma medida de desempenho de quão boa a rede é capaz em detectar um determinado tipo de padrão. É desejável que o  $ARL_{tx}$  seja

baixo para o estado do processo em que haja padrões não aleatórios e alto para o caso de padrões normais.

Assim, no teste do desempenho da rede neural, uma medida deve ser avaliada em termos de ambos os erros (tipo I e tipo II), isto é, tanto os padrões não aleatórios quanto os padrões aleatórios devem ser usados para testar e computar essa medida. Um sistema de reconhecimento de padrões não pode ser garantidamente útil na prática se ele não considera ambos os erros.

Foram computados assim as seguintes medidas para a avaliação da *performance* da metodologia:

- $R_i$  (ou *ROS*)- Percentagem de seqüências onde o alvo padrão foi obtido;
- $R_{ni}$  (ou *RONS*)- Percentagem de seqüências onde o alvo padrão não foi obtido;
- $ARL_t$  - *ARL* quando o alvo padrão foi obtido;
- $ARL_{tx}$  - *ARL* considerando toda a seqüência de dados (expressão 5.5);

Foram utilizadas diversas configurações para o treinamento da rede RBF mas todos os resultados podem ser agrupados nas 3 categorias, descritas na tabela 5.10.

**Tabela 5.10: Agrupamento dos experimentos com a rede RBF.**

Rede	Nº Max. Neurônios	Constante de Alargamento	SSE (%)	Vetor de Entrada
A	50	1	5	Original
B	100	0.9	2.5	Zonas
C	200	0.8	1	Original

Obs.: Os valores da tabela foram obtidos experimentalmente usando sistematicamente tentativa e erro conforme sugere Fredrickson e Tarassenko (1995). O número de neurônios foi incrementado no sentido de verificar o poder de generalização da rede. Redes com menor número de neurônios tendem a generalizar melhor mas apresentam problemas para atingir o erro mínimo desejado. Foram usados os seguintes valores iniciais para o número de neurônios: 10 (Billings e Zheng, 1995), 16 (Pao, 1989), 24 (Lippman, 1987), 50, 75, 100, 150, 200 e 400. As constantes de alargamento experimentadas foram definidas em função do desvio padrão das entradas residuais (nesse caso de valor normal unitário para os padrões sobre controle). Foram assim usados: 1, 0.9, 0.8 e 0.5. O SSE foi escolhido considerando limites mínimos para sustentar o poder de generalização. Foram utilizados: 0.1%, 1%, 2.5%, 5% e 10%. O vetor de entrada com 8 observações foi apresentado segundo as seguintes formas: original (sem nenhuma transformação) e em zonas (onde foi feita uma transformação linear decodificando os valores segundo intervalos). Tais vetores foram também apresentados numa determinada seqüência mas isso foi provado desnecessário pois as RBFs não são sensíveis a ordem de apresentação. As técnicas de projeto de experimentos são comumente usadas em experimentos dessa natureza e deverão ser consideradas em uma pesquisa futura.

As tabelas seguintes apresentam os resultados de simulação obtidos com a rede RBF. Para os padrões repetitivos como tendências, ciclos, mistura, sistemático e estratificação, seqüências de dados foram testadas considerando o método de inserção de pontos na forma da janela deslizante como mostrou a figura 5.7. Para cada uma dessas tabelas foram testadas seqüências de 100 cartas de controle com diferentes níveis de ruídos e diversos parâmetros. Cada uma dessas seqüências foi composta com 50 pontos para avaliar o *ARL*.

Para os tipos não repetitivos como os desvios da média, janelas independentes foram testadas. Existe somente um deslocamento da média em cada uma dessas janelas e a análise de *ARL* não é então desenvolvida. Foram usadas 500 janelas independentes para a avaliação desses tipos de padrões.



**Tabela 5.11: Medidas de desempenho da rede RBF para tendência crescente sob diversos parâmetros. A, B e C conforme tabela 5.10.**

Inclinação	Ruído	Rede	Rt	Rnt	ARLt	ARLtx
0.15	0.1	A	0.96	0.01	8.26	8.59
0.15	0.1	B	1.00	0.00	9.31	9.35
0.15	0.1	C	1.00	0.00	8.03	8.03
0.25	0.1	A	0.91	0.06	8.27	9.07
0.25	0.1	B	0.95	0.05	9.40	9.94
0.25	0.1	C	0.96	0.01	8.25	8.59
0.35	0.1	A	0.92	0.07	8.56	9.30
0.35	0.1	B	0.90	0.10	8.78	9.81
0.35	0.1	C	0.93	0.07	8.50	9.14
0.15	0.2	A	0.76	0.21	8.27	10.86
0.15	0.2	B	0.80	0.20	10.31	12.96
0.15	0.2	C	0.82	0.12	8.10	9.88
0.25	0.2	A	0.71	0.26	9.27	13.03
0.25	0.2	B	0.75	0.25	11.31	15.17
0.25	0.2	C	0.80	0.18	9.12	11.40
0.35	0.2	A	0.66	0.31	10.27	15.52
0.35	0.2	B	0.70	0.29	12.31	17.70
0.35	0.2	C	0.74	0.25	9.98	13.49
0.15	0.3	A	0.56	0.41	13.31	23.70
0.15	0.3	B	0.60	0.40	13.95	23.44
0.15	0.3	C	0.65	0.35	13.18	20.28
0.25	0.3	A	0.51	0.46	10.27	20.07
0.25	0.3	B	0.55	0.45	12.31	22.57
0.25	0.3	C	0.58	0.42	10.20	17.59
0.35	0.3	A	0.46	0.51	11.27	24.41
0.35	0.3	B	0.50	0.50	12.23	24.70
0.35	0.3	C	0.54	0.45	10.89	20.17

Obs.: Como pode ser visto acima, a performance da rede para os padrões de tendência variam significativamente. A taxa  $R_t$  também é bastante sensível ao aumento da inclinação, isto é, quanto maior a inclinação, menor o valor de  $R_t$ . Isso parece contradizer a razão de que uma acentuada tendência deveria ser mais fácil de ser detectada. Em fato, isso não acontece aqui pois nesse caso um ponto fora de controle (alem de três desvios) seria identificado automaticamente. Consequentemente, esse tipo de padrão não foi fortemente representado no conjunto de treinamento.

Ambos os valores de  $R_t$  e  $R_{nt}$  são afetados com o incremento do ruído aleatório das cartas de controle. Quando o desvio padrão do ruído aleatório aumenta, o  $R_t$  diminui e o  $R_{nt}$  aumenta. Isso é obvio pois uma tendência com ruído deve ser supostamente mais difícil de ser detectada. O valor  $ARL_t$  mostrou ser elevado para tendências com uma pequena inclinação e altos valores de ruídos. Em geral as redes tiveram um bom desempenho pois as tendências podem sempre ser detectadas com um  $ARL_t$  de no máximo 12.31 quando o primeiro padrão detectado foi a tendência. Isso e evidenciado pelo  $ARL_{tx}$  (ver parte superior direita da tabela).

Tabela 5.12: Medidas de desempenho da rede RBF para tendência decrescente. A, B e C conforme tabela 5.10.

Inclinação	Ruído	Rede	Rt	Rnt	ARLt	ARLtx
0.15	0.1	A	0.96	0.01	9.79	10.19
0.15	0.1	B	0.97	0.02	10.10	10.38
0.15	0.1	C	0.95	0.00	8.56	9.01
0.25	0.1	A	0.91	0.06	8.21	9.02
0.25	0.1	B	0.92	0.07	10.12	10.96
0.25	0.1	C	0.99	0.01	8.16	8.24
0.35	0.1	A	0.86	0.11	9.21	10.70
0.35	0.1	B	0.87	0.12	9.91	11.35
0.35	0.1	C	0.94	0.06	8.67	9.22
0.15	0.2	A	0.76	0.21	8.21	10.79
0.15	0.2	B	0.77	0.22	8.91	11.52
0.15	0.2	C	0.81	0.16	8.12	10.02
0.25	0.2	A	0.71	0.26	9.21	12.96
0.25	0.2	B	0.72	0.27	9.91	13.70
0.25	0.2	C	0.79	0.21	8.56	10.84
0.35	0.2	A	0.66	0.31	10.21	15.45
0.35	0.2	B	0.67	0.32	10.91	16.21
0.35	0.2	C	0.73	0.25	8.86	12.14
0.15	0.3	A	0.56	0.41	9.21	16.43
0.15	0.3	B	0.57	0.42	9.91	17.29
0.15	0.3	C	0.64	0.35	8.45	13.20
0.25	0.3	A	0.51	0.46	10.21	19.99
0.25	0.3	B	0.52	0.47	10.91	20.85
0.25	0.3	C	0.59	0.41	8.86	15.02
0.35	0.3	A	0.46	0.51	11.21	24.33
0.35	0.3	B	0.47	0.52	11.91	25.17
0.35	0.3	C	0.55	0.45	9.86	17.93

Obs.: Observando a tabela acima pode-se questionar porque a *performance* da rede para tendência crescente apresenta-se melhor do que para a tendência decrescente. Isso acontece pois, sendo os padrões de treinamento gerados randomicamente e independentemente, é possível que diferentes classes de padrões não foram igualmente representadas no conjunto de treinamento. Como resultado, não se torna muito apropriado comparar diferentes classes de padrões entre si. Ao invés disso, cada padrão preferivelmente deve ser avaliado separadamente.

Observe também que a *performance* do conjunto de teste e extrapolado em relação ao conjunto de treinamento desde que os valores dos parâmetros para ambos os conjuntos são diferentes. Por exemplo, no teste foi usado um ruído variando de  $0.1\sigma$  a  $0.3\sigma$  e no conjunto de treinamento os limites variaram diferentemente. O mesmo acontece com as amplitudes dos parâmetros dos padrões. Os conjuntos de treinamento e as medidas de *performance* foram deliberadamente projetadas dessa maneira para estudar a flexibilidade e a habilidade de generalização da rede RBF. Pode-se esperar um ótimo desempenho da rede se os conjuntos de padrões de teste forem exatas repetições do conjunto de treinamento.

Tabela 5.13: Medidas de desempenho da rede RBF para ciclos.

Amplitude	Ruído	Rede	Rt	Rnt	ARLt	ARLtx
1.5	0.1	A	0.95	0.00	8.60	9.01
1.5	0.1	B	0.99	0.00	9.60	9.67
1.5	0.1	C	1.00	0.00	8.56	8.56
2	0.1	A	0.90	0.05	8.70	9.62
2	0.1	B	0.94	0.04	9.12	9.67
2	0.1	C	0.98	0.00	8.67	8.85
2.5	0.1	A	0.85	0.10	8.16	9.55
2.5	0.1	B	0.89	0.09	8.45	9.46
2.5	0.1	C	0.94	0.03	8.11	8.63
1.5	0.2	A	0.75	0.20	8.60	11.41
1.5	0.2	B	0.79	0.19	10.10	12.73
1.5	0.2	C	0.83	0.14	8.13	9.80
2	0.2	A	0.70	0.25	8.60	12.22
2	0.2	B	0.74	0.24	11.10	14.93
2	0.2	C	0.78	0.20	8.45	10.83
2.5	0.2	A	0.65	0.30	9.60	14.68
2.5	0.2	B	0.69	0.29	12.10	17.45
2.5	0.2	C	0.72	0.28	9.54	13.25
1.5	0.3	A	0.55	0.40	9.78	17.65
1.5	0.3	B	0.59	0.38	11.10	18.71
1.5	0.3	C	0.66	0.33	9.67	14.65
2	0.3	A	0.50	0.45	9.60	19.05
2	0.3	B	0.54	0.44	12.10	22.27
2	0.3	C	0.57	0.42	9.52	16.70
2.5	0.3	A	0.45	0.50	10.60	23.35
2.5	0.3	B	0.49	0.48	13.10	26.56
2.5	0.3	C	0.53	0.46	10.12	19.09

Obs.: A performance da rede na classificação de ciclos varia fortemente dependendo da amplitude do ciclo e do ruído associado. Ambos  $R_t$  e  $ARL_t$  são bastante sensíveis ao efeito da amplitude: quanto maior a amplitude, menor o valor  $R_t$  e do  $ARL_t$ .  $R_t$  e  $ARL_t$  são também sensíveis ao ruído: quando o desvio padrão do ruído é aumentado, o valor de  $R_t$  piora e o  $ARL_t$  aumenta. Similar à *performance* dos padrões de tendência, uma vez classificado corretamente como ciclo, o  $ARL_t$  resultante foi excelente com valores inferiores a 10 pontos. Além disso, existiram somente alguns padrões classificados incorretamente quanto ao alvo (por exemplo, um ciclo classificado como mistura). Isso indica que a falsa detecção de padrões é bastante improvável. Observe que o  $ARL_{tx}$ , o qual incorpora os valores  $R_t$  e  $ARL_t$  em um simples valor, mostrou ser um útil indicador aqui. Por exemplo, o  $ARL_t$  é 9.60 para ciclos com (amplitude, ruído, rede)=(1.5, 0.1, C) e (2, 0.3, A), mesmo com os valores  $R_t$  sendo bastante diferentes, isto é, 0.99 e 0.50. Essa diferença é ampliada pelo  $ARL_{tx}$ , isto é, 9.67 e 19.05.

Tabela 5.14: Medidas de desempenho da rede RBF para padrão sistemático.

Amplitude	Ruído	Rede	Rt	Rnt	ARLt	ARLtx
1.5	0.1	A	0.98	0.01	8.02	8.15
1.5	0.1	B	0.98	0.00	8.01	8.16
1.5	0.1	C	0.99	0.00	8.01	8.09
2	0.1	A	1.00	0.00	8.09	8.11
2	0.1	B	1.00	0.00	8.09	8.11
2	0.1	C	1.00	0.00	8.07	8.07
2.5	0.1	A	0.99	0.01	8.05	8.13
2.5	0.1	B	1.00	0.00	8.09	8.11
2.5	0.1	C	1.00	0.00	8.05	8.05
1.5	0.2	A	1.00	0.00	8.09	8.11
1.5	0.2	B	1.00	0.00	8.09	8.11
1.5	0.2	C	1.00	0.00	8.01	8.01
2	0.2	A	1.00	0.00	8.08	8.11
2	0.2	B	0.99	0.01	8.05	8.13
2	0.2	C	1.00	0.00	8.03	8.03
2.5	0.2	A	1.00	0.00	8.08	8.11
2.5	0.2	B	0.99	0.01	8.06	8.12
2.5	0.2	C	1.00	0.00	8.04	8.04
1.5	0.3	A	0.99	0.00	12.30	12.43
1.5	0.3	B	1.00	0.00	10.13	10.13
1.5	0.3	C	1.00	0.00	9.78	9.78
2	0.3	A	0.99	0.01	8.06	8.12
2	0.3	B	1.00	0.00	8.09	8.11
2	0.3	C	1.00	0.00	8.01	8.01
2.5	0.3	A	1.00	0.00	8.09	8.11
2.5	0.3	B	0.99	0.00	8.05	8.13
2.5	0.3	C	1.00	0.00	8.04	8.04

Obs.: O desempenho para padrões sistemáticos é quase ideal para os parâmetros estudados. Os valores de *ARLt* são aproximadamente iguais ao comprimento da janela de pontos com 8 observações, exceto quando a amplitude do padrão é pequena, acompanhada por um grande ruído. A rede teve portanto um bom desempenho pois todos os padrões puderam ser detectados com um *ARLt* de menos de 12.30. Devido ao *Rt* ser quase sempre igual a 1, quase não houve falsa detecção.

Tabela 5.15: Medidas de desempenho da rede RBF para padrões de estratificação.

Offset	Ruído	Rede	Rt	Rnt	ARLt	ARLtx
-2	0.1	A	0.98	0.01	8.12	8.25
-2	0.1	B	1.00	0.00	8.11	8.11
-2	0.1	C	1.00	0.00	8.04	8.04
0	0.1	A	0.99	0.00	8.49	8.58
0	0.1	B	0.98	0.00	8.25	8.40
0	0.1	C	1.00	0.00	8.12	8.12
2	0.1	A	0.98	0.01	8.45	8.62
2	0.1	B	0.99	0.00	8.23	8.29
2	0.1	C	1.00	0.00	8.07	8.07
-2	0.2	A	0.98	0.00	8.47	8.61
-2	0.2	B	0.99	0.00	8.89	8.98
-2	0.2	C	1.00	0.00	8.27	8.27
0	0.2	A	0.98	0.01	8.76	8.94
0	0.2	B	0.98	0.00	9.48	9.66
0	0.2	C	1.00	0.00	8.28	8.28
2	0.2	A	0.99	0.01	9.29	9.39
2	0.2	B	1.00	0.01	9.42	9.45
2	0.2	C	1.00	0.00	9.07	9.12
-2	0.3	A	0.99	0.00	10.08	10.23
-2	0.3	B	1.00	0.00	10.06	10.06
-2	0.3	C	1.00	0.00	9.90	9.90
0	0.3	A	1.00	0.00	11.13	11.14
0	0.3	B	0.98	0.00	11.40	11.63
0	0.3	C	1.00	0.00	10.68	10.68
2	0.3	A	0.99	0.00	10.89	10.98
2	0.3	B	0.98	0.01	10.36	10.54
2	0.3	C	1.00	0.00	10.28	10.28

Obs.: Como para padrões sistemáticos, as medidas de desempenho aqui são quase ideais para os parâmetros estudados. O valor do *ARLt* frequentemente mostra uma tendência de aumento, com o aumento do ruído. O *ARLt* sempre permanece pequeno quando o centro do padrão tem um valor perto da média do processo. A rede teve portanto um bom desempenho pois, exceto em dois casos, todos os padrões puderam ser detectados com um *ARLt* inferior a 11. Devido ao *Rt* ser quase sempre igual a 1, quase não houve falsa detecção.

Tabela 5.16: Medidas de desempenho da rede RBF para padrões de mistura.

Amplitude	Ruído	Rede	Rt	Rnt	ARLt	ARLtx
1.75	0.1	A	0.97	0.02	8.47	8.73
1.75	0.1	B	0.97	0.03	8.43	8.70
1.75	0.1	C	1.00	0.00	8.16	8.16
2	0.1	A	1.00	0.00	9.96	9.97
2	0.1	B	0.98	0.01	8.99	9.17
2	0.1	C	1.00	0.00	8.78	8.78
2.25	0.1	A	1.00	0.00	9.81	9.85
2.25	0.1	B	0.98	0.02	8.93	9.12
2.25	0.1	C	1.00	0.00	8.81	8.81
1.75	0.2	A	0.96	0.04	8.17	8.48
1.75	0.2	B	0.99	0.01	9.39	9.50
1.75	0.2	C	1.00	0.00	8.11	8.12
2	0.2	A	0.98	0.02	9.02	9.20
2	0.2	B	0.96	0.04	8.03	8.36
2	0.2	C	1.00	0.00	8.97	9.01
2.25	0.2	A	0.98	0.02	9.25	9.39
2.25	0.2	B	0.98	0.02	8.93	9.12
2.25	0.2	C	1.00	0.00	8.02	8.02
1.75	0.3	A	1.00	0.00	10.63	10.68
1.75	0.3	B	0.97	0.03	12.06	12.47
1.75	0.3	C	1.00	0.00	10.56	10.60
2	0.3	A	0.98	0.02	9.45	9.66
2	0.3	B	0.96	0.02	9.67	10.03
2	0.3	C	1.00	0.00	8.65	8.65
2.25	0.3	A	0.99	0.01	8.67	8.74
2.25	0.3	B	0.96	0.04	8.96	9.32
2.25	0.3	C	1.00	0.00	8.62	8.62

Obs.: O desempenho para os padrões de mistura foi bastante consistente com respeito aos vários parâmetros dos padrões. Para padrões com grande amplitude, os valores do *ARLt* são relativamente pequenos. O *ARLt* aumenta um pouco quando uma pequena amplitude é acompanhada por uma grande componente de ruído. Os valores *Rt* e *Rnt* são aproximadamente complementares e os padrões de mistura tiveram um *ARLt* em torno de 9 observações.

**Tabela 5.17: Medidas de desempenho da rede RBF para deslocamento positivo da média.**

Amplitude	Ruído	Rede	Deslocamento no 3º Ponto		Deslocamento no 5º Ponto	
			ROS	RONS	ROS	RONS
1.5	0.1	A	0.22	0.77	0.76	0.14
1.5	0.1	B	0.51	0.49	0.84	0.16
1.5	0.1	C	0.53	0.47	0.85	0.14
2	0.1	A	0.21	0.79	0.82	0.18
2	0.1	B	0.58	0.40	0.86	0.14
2	0.1	C	0.59	0.40	0.92	0.08
2.5	0.1	A	0.78	0.15	0.93	0.07
2.5	0.1	B	0.86	0.10	0.93	0.05
2.5	0.1	C	0.89	0.09	0.98	0.02
1.5	0.2	A	0.29	0.71	0.68	0.32
1.5	0.2	B	0.23	0.77	0.74	0.26
1.5	0.2	C	0.40	0.55	0.80	0.20
2	0.2	A	0.56	0.44	0.78	0.18
2	0.2	B	0.55	0.45	0.81	0.19
2	0.2	C	0.58	0.40	0.89	0.11
2.5	0.2	A	0.40	0.60	0.82	0.16
2.5	0.2	B	0.55	0.45	0.88	0.12
2.5	0.2	C	0.59	0.38	0.95	0.05
1.5	0.3	A	0.55	0.45	0.56	0.44
1.5	0.3	B	0.56	0.42	0.64	0.32
1.5	0.3	C	0.64	0.36	0.69	0.31
2	0.3	A	0.52	0.46	0.62	0.28
2	0.3	B	0.40	0.60	0.77	0.23
2	0.3	C	0.46	0.45	0.79	0.21
2.5	0.3	A	0.53	0.47	0.73	0.25
2.5	0.3	B	0.45	0.52	0.81	0.19
2.5	0.3	C	0.58	0.42	0.84	0.16

Obs.: Como descrito anteriormente, cada janela do desvio da média contém exatamente um deslocamento em um ponto intermediário da janela. É previsível que a rede treinada tivesse uma boa *performance* somente para o modo como ela foi treinada. Entretanto, testando-se a rede para deslocamentos ocorrendo em pontos distintos do modo como ela foi treinada, a *performance* foi também satisfatória. Nessas simulações somente os valores de *ROS* e de *RONS* representam medidas importantes. Esses valores não precisam ser complementares em relação a 1 pois o algoritmo pode não classificar nenhum dos padrões. Como pode ser visto, o desempenho é melhor quando o deslocamento ocorre no meio da janela (quinta observação). Para aqueles padrões gerados com um deslocamento na terceira observação, *ROS* é bem pequeno e, na verdade, o padrão mais frequentemente identificado foi o de tendência. Também, os valores de *ROS* e *RONS* são muito sensíveis ao efeito do ruído, isto é, quanto menor o ruído, maior o valor de *ROS* e menor o valor de *RONS*. Além disso, como pode ser esperado, *ROS* e *RONS* são bastante sensíveis aos valores da amplitude do desvio da média. Quanto maior a amplitude, maior o valor do *ROS* e menor o valor de *RONS*. A melhor *performance* foi obtida quando uma grande amplitude ocorrendo no meio da janela de pontos é acompanhada de um pequeno ruído, isto é, *ROS*=0.921.

**Tabela 5.18: Medidas de desempenho da rede RBF para deslocamento negativo da média.**

Amplitude	Ruído	Rede	Deslocamento no 3º Ponto		Deslocamento no 5º Ponto	
			ROS	RONS	ROS	RONS
1.5	0.1	A	0.20	0.78	0.73	0.25
1.5	0.1	B	0.32	0.68	0.82	0.18
1.5	0.1	C	0.47	0.53	0.84	0.16
2	0.1	A	0.32	0.65	0.82	0.15
2	0.1	B	0.47	0.53	0.84	0.16
2	0.1	C	0.48	0.51	0.95	0.05
2.5	0.1	A	0.89	0.08	0.92	0.08
2.5	0.1	B	0.89	0.11	0.95	0.02
2.5	0.1	C	0.94	0.06	0.98	0.02
1.5	0.2	A	0.29	0.68	0.62	0.38
1.5	0.2	B	0.59	0.41	0.68	0.28
1.5	0.2	C	0.61	0.39	0.79	0.21
2	0.2	A	0.39	0.60	0.72	0.28
2	0.2	B	0.23	0.77	0.81	0.15
2	0.2	C	0.59	0.40	0.90	0.10
2.5	0.2	A	0.21	0.79	0.82	0.18
2.5	0.2	B	0.45	0.55	0.88	0.12
2.5	0.2	C	0.48	0.43	0.94	0.04
1.5	0.3	A	0.27	0.67	0.58	0.42
1.5	0.3	B	0.38	0.61	0.65	0.35
1.5	0.3	C	0.43	0.57	0.68	0.28
2	0.3	A	0.21	0.79	0.68	0.32
2	0.3	B	0.23	0.75	0.78	0.22
2	0.3	C	0.25	0.75	0.79	0.21
2.5	0.3	A	0.38	0.61	0.75	0.22
2.5	0.3	B	0.54	0.46	0.84	0.16
2.5	0.3	C	0.55	0.44	0.85	0.15

Obs.: A melhor *performance* foi obtida quando uma grande amplitude ocorrendo no meio da janela de pontos é acompanhada de um pequeno ruído, isto é, (amplitude, ruído, rede)=(2.5,0.10, C).



Tabela 5.19: Análise de Variância para a taxa de acertos Rt. Comparação do desempenho das redes A, B e C.

Rt		TendUp	TendDown	Ciclos	Sistema	Estratif	Mistura	Média		A	B	C
0.1	A	0.96	0.96	0.95	0.98	0.98	0.97	0.97		0.97	0.99	0.99
0.1	B	1.00	0.97	0.99	0.98	1.00	0.97	0.99		0.95	0.96	0.99
0.1	C	1.00	0.95	1.00	0.99	1.00	1.00	0.99		0.93	0.94	0.97
.								0.95		0.87	0.89	0.91
.								.		0.85	0.86	0.89
.								.		0.82	0.84	0.86
										0.77	0.79	0.82
										0.75	0.76	0.79
										0.73	0.73	0.77

Sumário				
Grupos	Obs.:	Soma	Média	Variação
A	9	7.64654	0.849616	0.007982
B	9	7.749719	0.86108	0.008146
C	9	7.999261	0.888807	0.006945

ANOVA						
Fonte de Variação	SS	df	MS	F	P-value	F crit
Entre Grupos	0.007308	2	0.003654	0.475135	0.627526	3.402832
Dentro do Grupo	0.184583	24	0.007691			
Total	0.191891	26				

Obs.: A ANOVA mostra que a hipótese nula não foi rejeitada a um nível de significância de 5% levando em consideração os valores de Rt. A rede C, contudo, pode ser considerada superior as redes A e B, levando em conta as novas avaliações feitas com outras medidas de desempenho. Para as medidas de *ARL<sub>t</sub>*, *ROS* e *RONs* a hipótese nula de homogeneidade entre as redes foi rejeitada a um nível de 10% (para um mesmo *Fcrit*=3.40), como mostrado abaixo.

	F	P-value
<i>ARL<sub>t</sub></i>	3.059526	0.06553
<i>ROS</i>	3.174015	0.059837
<i>RONs</i>	2.808031	0.080206

Com um número reduzido de neurônios (50) e com um maior erro limite (5%) a rede A não conseguiu um ótimo poder de generalização. A constante de alargamento de valor unitário provavelmente favoreceu o aumento da falsa detecção de padrões. A rede C apresentou maiores valores de Rt para a grande maioria dos padrões testados.

Tabela 5.19: Análise de Variância para a taxa de acertos Rt. Comparação do desempenho das redes A, B e C.

Rt		TendUp	TendDown	Ciclos	Sistema	Estratíf	Mistura	Média		A	B	C
0.1	A	0.96	0.96	0.95	0.98	0.98	0.97	0.97		0.97	0.99	0.99
0.1	B	1.00	0.97	0.99	0.98	1.00	0.97	0.99		0.95	0.96	0.99
0.1	C	1.00	0.95	1.00	0.99	1.00	1.00	0.99		0.93	0.94	0.97
.								0.95		0.87	0.89	0.91
.								.		0.85	0.86	0.89
.								.		0.82	0.84	0.86
.								.		0.77	0.79	0.82
.								.		0.75	0.76	0.79
.								.		0.73	0.73	0.77

Sumário				
Grupos	Obs.:	Soma	Média	Variancia
A	9	7.64654	0.849616	0.007982
B	9	7.749719	0.86108	0.008146
C	9	7.999261	0.888807	0.006945

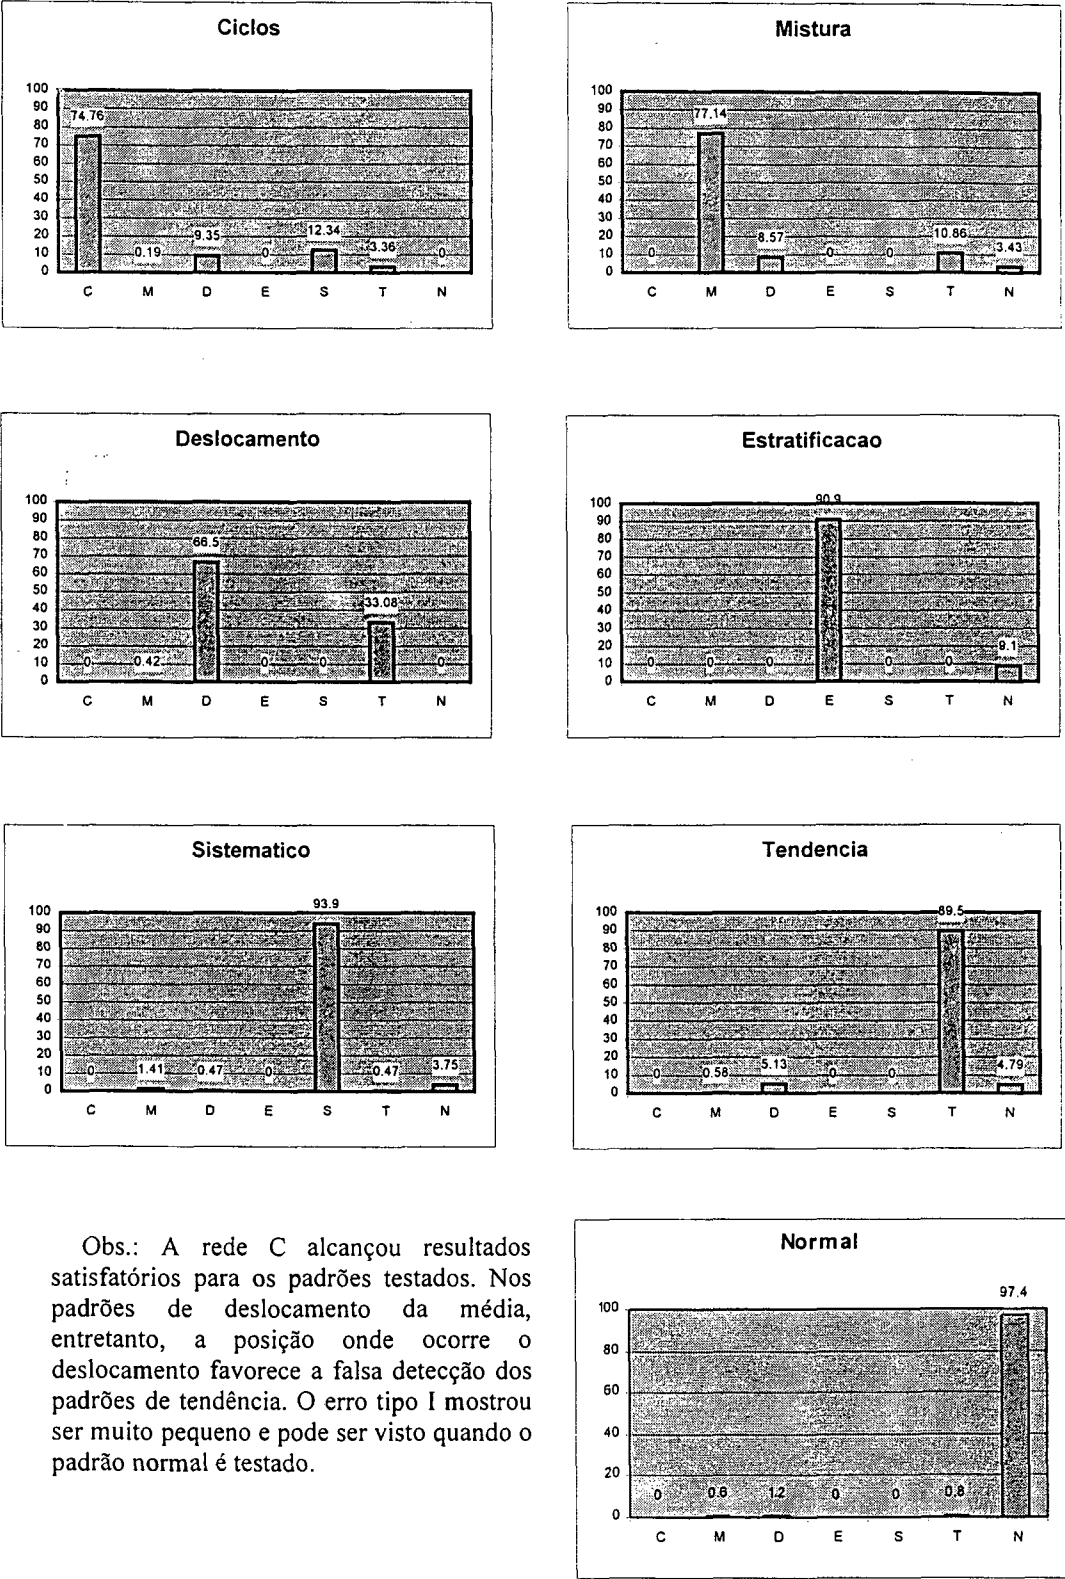
ANOVA						
Fonte de Variação	SS	df	MS	F	P-value	F crit
Entre Grupos	0.007308	2	0.003654	0.475135	0.627526	3.402832
Dentro do Grupo	0.184583	24	0.007691			
Total	0.191891	26				

Obs.: A ANOVA mostra que a hipótese nula não foi rejeitada a um nível de significância de 5% levando em consideração os valores de Rt. A rede C, contudo, pode ser considerada superior as redes A e B, levando em conta as novas avaliações feitas com outras medidas de desempenho. Para as medidas de *ARL<sub>t</sub>*, *ROS* e *RONs* a hipótese nula de homogeneidade entre as redes foi rejeitada a um nível de 10% (para um mesmo *Fcrit*=3.40), como mostrado abaixo.

	F	P-value
<i>ARL<sub>t</sub></i>	3.059526	0.06553
<i>ROS</i>	3.174015	0.059837
<i>RONs</i>	2.808031	0.080206

Com um número reduzido de neurônios (50) e com um maior erro limite (5%) a rede A não conseguiu um ótimo poder de generalização. A constante de alargamento de valor unitário provavelmente favoreceu o aumento da falsa detecção de padrões. A rede C apresentou maiores valores de Rt para a grande maioria dos padrões testados.

Figura 5.15: Histogramas dos resultados do reconhecimento de padrões utilizando a Rede RBF C (conforme tabela 5.10).



Obs.: A rede C alcançou resultados satisfatórios para os padrões testados. Nos padrões de deslocamento da média, entretanto, a posição onde ocorre o deslocamento favorece a falsa detecção dos padrões de tendência. O erro tipo I mostrou ser muito pequeno e pode ser visto quando o padrão normal é testado.

**Tabela 5.20: Comparação de resultados do sistema proposto com respostas de especialistas.**

<b>Padrão</b>	<b>A</b>	<b>B</b>	<b>C</b>	<b>Espec. 1</b>	<b>Espec. 2</b>	<b>Espec. 3</b>
T(.15)	T(.15)	T(.15)	T(.15)	M	T	T
C(1.5)	C(2.0)*	C(1.5)	C(2.0)*	C	C	M
S(1.5)	S(1.5)	S(1.5)	S(1.5)	S	S	S
M(1.75)	M(1.75)	M(1.75)	M(1.75)	S	C	C
D(1.50)	D(1.50)	D(1.50)	D(1.50)	D	D	D
E(-0.20)	N	N	N	N	N	N
T(.25)	T(.25)	T(.25)	T(.25)	T	T	M
C(2.5)	C(2.5)	C(2.5)	C(2.5)	C	M	C
S(2.0)	S(1.5)*	S(2.0)	S(2.0)	S	S	S
M(2.0)	M(2.0)	M(2.25)*	M(2.0)	M	M	M
D(2.0)	D(2.0)	D(2.0)	D(2.0)	M	D	D
E(0.0)	N	N	N	N	N	N
T(.35)	T(.35)	T(.35)	T(.35)	T	T	T
C(3.5)	C(3.5)	C(3.5)	C(3.5)	C	C	C
S(2.5)	S(2.5)	S(2.5)	S(2.0)*	S	S	S
M(2.25)	M(2.25)	M(2.25)	M(2.25)	M	S	M
D(2.50)	D(2.50)	D(2.50)	D(2.50)	D	D	S
E(0.20)	N	N	N	N	N	N
T(-0.15)	T(-0.15)	T(-0.15)	T(-0.15)	M	T	T
D(-1.5)	D(-1.5)	D(-1.5)	D(-1.5)	D	D	C
T(-0.25)	T(-0.35)*	T(-0.25)	T(-0.25)	T	T	T
D(-2.0)	D(-2.0)	D(-1.50)*	D(-2.0)	D	D	M
T(-0.35)	T(-0.35)	T(-0.35)	T(-0.35)	T	M	T
D(-2.5)	C	D(-2.5)	D(-2.5)	C	D	N
<b>Nº acertos</b>	<b>20</b>	<b>21</b>	<b>21</b>	<b>16</b>	<b>17</b>	<b>14</b>

Obs.: As letras T, C, S, M, D e E são gráficos com os padrões de Tendência, Ciclo, Sistemático, Mistura, Desvio da Média e Estratificação, respectivamente. O padrão Natural está representado pela letra N, e as letras A, B e C são as redes descritas na tabela 5.10.

Obs.: Os três especialistas em controle de qualidade foram escolhidos e concordaram em participar da pesquisa. Eles trabalharam independentemente e a eles foram apresentados os mesmos gráficos em ordem aleatória. Foram considerados acertos todos os resultados em que o padrão correspondia ao verdadeiro, independente da amplitude. Os resultados em asterisco representam a falha de reconhecimento da correta amplitude padrão, muito embora o resultado seja correto. Observando-se a taxa de acertos, pode-se ver que os resultados alcançados pelas redes foram certamente positivos.

## **Capítulo 6 – Aplicação:**

### ***Reconhecimento de Padrões em Sinais EEG***

---

#### **6.1 Introdução**


Uma vasta literatura tem considerado a teoria de redes neurais aplicados à área médica. Estudos de falha renal, análise de problemas de insuficiência cardíaca, técnicas de diagnóstico diferencial de hipertensão, análise de vectorcardiografia, tratamento de diabetes, análise da atividade cardíaca, exame clínico de pacientes,... são exemplos de trabalhos publicados (Adlassnig,1982; Degani e Bortolan, 1987) Em todos esses trabalhos, diferentes níveis de conhecimento tem sido empregados: em alguns casos os métodos são apenas propostos; alguns exemplos são usados para justificar uma metodologia; finalmente algumas aplicações tem usado o estágio de completa utilização. O método proposto aqui foi simulado a partir de um banco de dados real obtido por meio de um sistema computadorizado de aquisição do sinal eletrencefalográfico (sinal EEG). Desta forma, foram utilizados extensamente os recursos do sistema de Vídeo EEG, desenvolvido pela empresa *Neurotec – Pesquisa e Desenvolvimento em Biomedicina* (<http://www.neurotec.com.br>), hoje a principal empresa em nosso país nessa área. Os resultados dessa metodologia irão num futuro próximo possivelmente ser viabilizados para centenas de profissionais que utilizam os produtos *Neurotec* que poderão, como retorno, dar novos rumos a esse trabalho.

Essa aplicação foi escolhida tendo em vista a generalização da metodologia exposta nos capítulos anteriores. Na próxima seção serão discutidos rapidamente alguns aspectos da atividade EEG e sua caracterização quanto a uma série temporal nos moldes de um sistema de manufatura automático. Na seção 6.3 será feita a descrição do problema a ser abordado, levando em conta a inserção do sistema de reconhecimento de padrões proposto anteriormente. Na seção 6.4 serão descritos os passos para a obtenção dos resultados e a análise de desempenho da metodologia, além de várias outras considerações específicas a esse caso.

## 6.2 Sinais EEG

A eletrencefalografia é hoje uma bem definida área de atuação para o médico que investiga qualquer patologia do sistema nervoso central. Ela existe a mais de um século e tem como principal objetivo a avaliação da atividade elétrica cerebral. O sinal EEG, como mostra a figura 6.1, obtido a partir do córtex humano, revela na verdade, uma série temporal de amplitudes (da ordem de  $\mu\text{V}$ ) e a morfologia da série obtida está relacionada com as patologias funcionais do cérebro. Os padrões comuns para a análise quantitativa do sinal EEG tem sido elaborados por sociedades como a *International Society for Brain Electromagnetic Topography (ISBET)*, e a *International Society for Neuroimaging in Psychiatry (ISNIP)*, entre outras, que fornecem as “regras” para a aquisição do sinal EEG e sua significação quanto a critérios de diagnóstico.

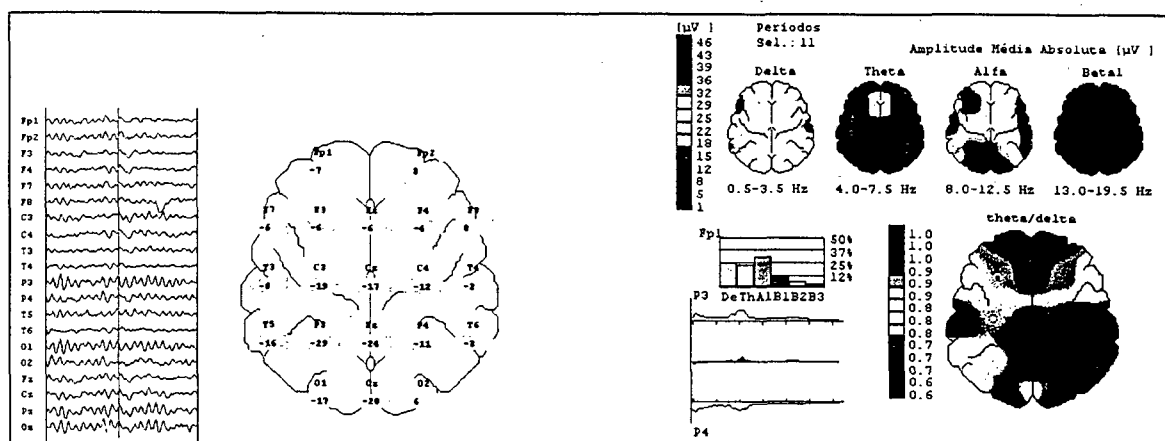
**Figura 6.1: Sinal EEG.**



Obs.: O Sinal EEG representa uma série temporal de amplitudes (da ordem de  $\mu\text{V}$ ) em baixa frequência.

O eletroencefalograma é um gráfico obtido a partir de forças elétricas produzidas pelo cérebro. Devido ao corpo poder conduzir correntes elétricas, tais forças podem ser captadas na superfície cerebral por meio de eletrôdos instalados no couro cabeludo. O EEG padrão utiliza convencionalmente um sistema de 20 eletrôdos dispostos segundo um sistema internacional denominado SI 10-20, como mostra a figura 6.2. Tal figura mostra também o sinal EEG obtido segundo um determinado referencial e alguns parâmetros quantitativos do sistema.

**Figura 6.2: Sinal EEG computadorizado obtido usando o SI 10-20.**



Obs.: Visualização de alguns parâmetros quantitativos. O Especialista utiliza-se de cores, tabelas e diagramas obtidos após uma análise temporal, frequencial e estatística feita sobre o sinal EEG (*Neuromap/Neurotec*).

O sinal EEG, em um equipamento analógico, é normalmente registrado em um papel com 8 canais (existem aparelhos com 12, 20, 24 ou mais canais). Nos aparelhos digitais e computadorizados (como o empregado aqui) o sinal aparece na tela de um computador podendo ser então impresso. Algumas características desse sinal são: (i) série temporal randômica e estocástica de amplitudes (na ordem de  $\mu\text{V}$ ), (ii) frequência de 0 a 70 Hz (geralmente são usados filtros baseados na Transformada Rápida de Fourier para eliminar frequências maiores que 32 Hz).

As principais alterações do sinal EEG vistas em um exame eletrencefalográfico podem ser geralmente divididas em cinco categorias de anormalidades (Duffy, Iyer, Surwillo, 1989);

- 1) Ritmos de fundo: (a) Ritmos Alfa: Encefalopatias tóxicas, metabólicas e infecciosas de diversas etiologias; demência; hipertireoidismo, lesões, coma,... (b) Ritmo Beta: lesões corticais destrutivas, hematomas, efeitos de droga ... (c) Outras: morte cerebral, hipoxia ...
- 2) Padrão do sono: hematomas subdurais, síndrome de Sturge-Weber, lesões estruturais, etc...
- 3) Baixa atividade: Irda, Firda, Oirda, acidentes cerebrovasculares, tumores intracranianos, encefalopatias focais, encefalopatias difusas, ...

- 4) Paroxísmos epileptógenos: Descargas epileptiformes, *Spikes*, *Sharp-wave*, *Polyspikes*, Hipsarritmia, padrões ictal, sincronia bilateral secundária, Ritmo *Breach*, Sreda, ...
- 5) Padrões paroxísticos periódicos: SSPE, Síndrome de Jakob-Creutzfeldt, *Pleds*, ...

### 6.3 Caracterização do problema

Dois problemas comumente encontrados na análise da atividade EEG são considerados nessa aplicação. Ambos estão relacionados com a detecção de sinais anômalos ao sinal EEG. Em traçados com pouca duração, a identificação dessas anormalidades apesar de simples, requerem muitos aspectos de reconhecimento de padrões e depende em muito do analista do sinal EEG. Em longos traçados, especialmente em casos de monitoração de pacientes através de Vídeo EEG ou Monitor Cerebral, a quantidade de informações torna-se absurda para a análise manual pois o analista certamente não tem capacidade (e paciência?!) para investigar todo um traçado eletrográfico (em alguns casos mais de 24 horas) onde o que mais importa são alguns segundos de descarga patológica. Tais tipos de anormalidades são sucintamente descritas a seguir


#### 1 - Sinais Patológicos

O primeiro problema consiste na identificação e caracterização de sinais anômalos de origem patológica tais como *spikes*, descargas epiléticas, certas morfologias de ondas, etc.. como mostram a figura 6.3.

Nesses tipos de sinais busca-se a definição de um diagnóstico pelo especialista quanto ao tipo de patologia do paciente. Uma comum mas importante informação sobre isso é que mesmo com os incríveis avanços dos sistemas atuais de reconhecimento de padrões, a avaliação médica não pode nunca ser negligenciada. O especialista nessa área nunca deve ser conduzido a pensar que o computador está dando o diagnóstico do paciente. Essa recomendação tem sido enfatizada em praticamente todos os tipos de equipamentos médicos com finalidades de auxílio ao diagnóstico.



**Figura 6.3: Alguns exemplos de sinais patológicos.**

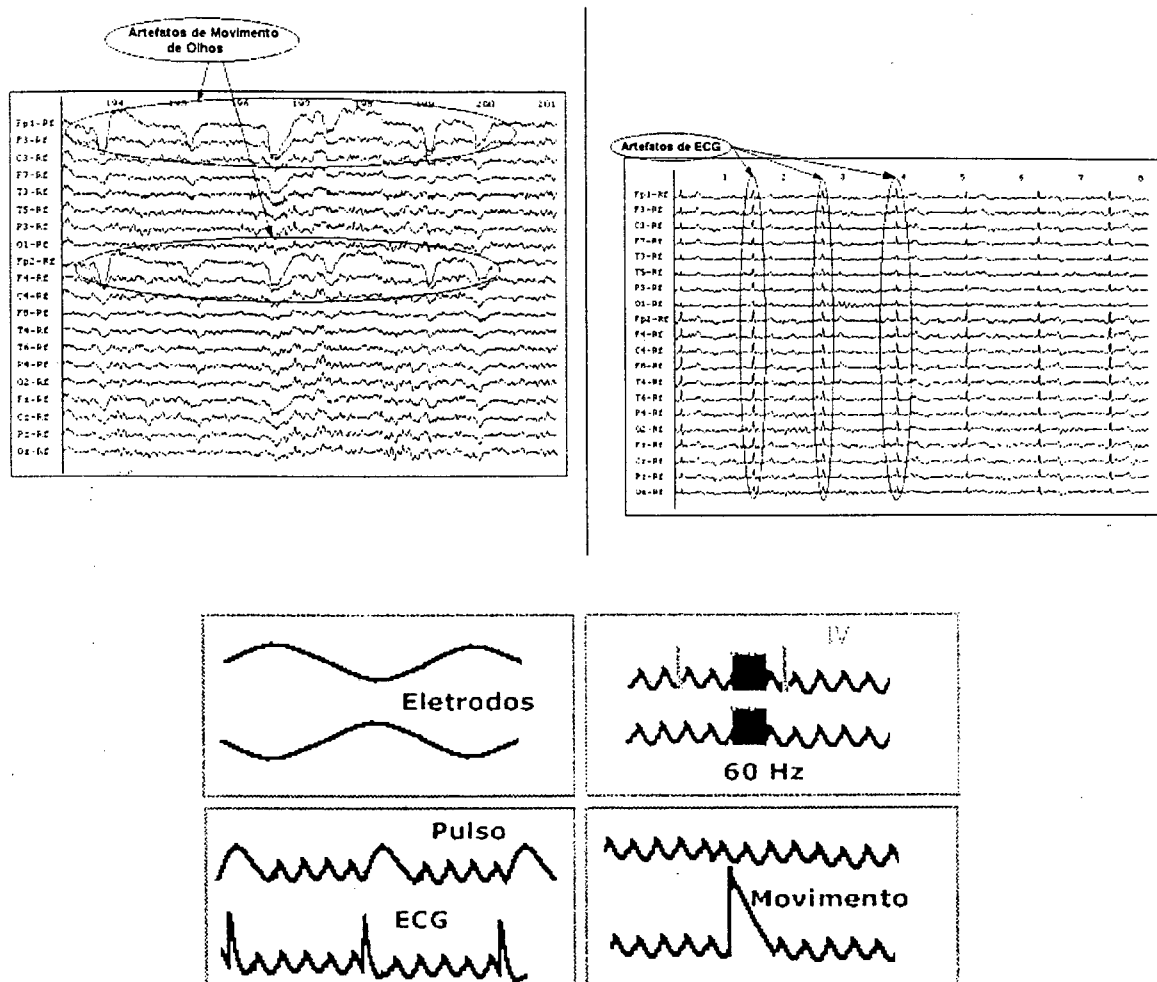


## 2 - Sinais de Artefatos

Um segundo caso consiste na identificação de artefatos, que são comumente sinais representando movimentos musculares ou interferências não patológicas que invariavelmente prejudicam a análise do traçado EEG. A figura seguinte exemplifica esses tipos de artefatos encontrados na representação da atividade elétrica cerebral.

Para esses tipos de sinais o que se deseja é que se tenha uma indicação de que alguma característica estranha está interferindo no traçado e portanto deve haver a interferência do especialista (verificando eletródos, condutividade, resistência ôhmica, movimentos musculares, ou qualquer outra interferência).

**Figura 6.4: Artefatos que contaminam a atividade EEG. (Equipamento Neuromap/Neurotec).**

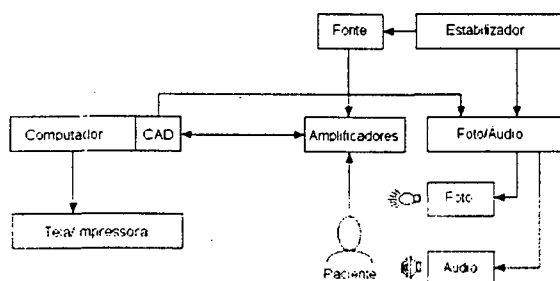


#### 6.4 Desenvolvimento

A metodologia descrita nos capítulos anteriores foi aqui utilizada para a identificação e caracterização de anomalias (artefatos ou sinais patológicos) em um traçado EEG de longa duração. A entrada para o sistema foi então o sinal EEG e a saída foi a caracterização do sinal EEG (contendo anormalidade ou não). Os resultados alcançados com a metodologia empregada foram extremamente positivos.

A figura seguinte mostra o *hardware* básico utilizado para a aplicação da rede neural na tarefa de reconhecimento de padrões da atividade EEG.

**Figura 6.5: Hardware básico utilizado.(Neuromap/Neurotec).**



*Sistema de Registro e Análise da atividade do EEG em 25 canais sendo:*

20 canais EEG;

4 canais monitoração auxiliares;

1 canal marcador de pulsos do foto estimulador;

*Características dos Amplificadores*

Ganho: 20000;

Constantes de tempo: 0,1s ; 0,3s ; 0,6s ; 1,0s;


Rejeição de modo Comum: maior que 110 Db;

*Conversor A/D*

Número de Bits: 12;

Taxa de Amostragem: 256 Hz;

Obs.: Opcionalmente pode ser utilizado um computador *Laptop*



*Requisitos Mínimos de Hardware:*

Vídeo-EEG: computador Pentium 166 MHz com 32 MB RAM, HDD 4GB, Windows

Inicialmente foi empregado o sinal elétrico de apenas um canal por vez do sinal EEG (apenas uma série temporal) mas uma abordagem com múltiplos canais é altamente desejável e será implementada num futuro próximo. Nesse caso a velocidade de computação de diversas redes neurais (supondo inicialmente uma rede neural para cada canal EEG operando paralelamente) e a taxa de amostragem do sinal EEG devem ter uma solução de compromisso.

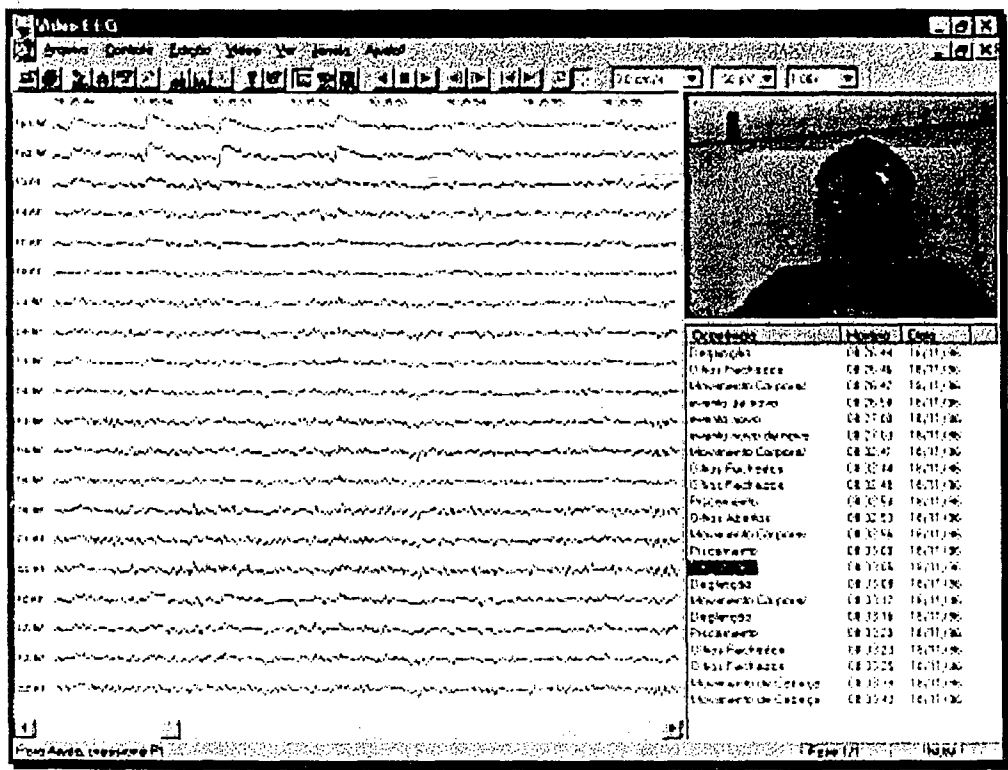
Uma abordagem inicial tendo em vista o reconhecimento de padrões anômalos do sinal EEG foi testada e é sumarizada a seguir.

### Monitoramento do Vídeo EEG

Nos sistemas de Vídeo EEG Digital a identificação de anomalias resultantes do reconhecimento de padrões feito com as redes neurais deve ser armazenada em tempo

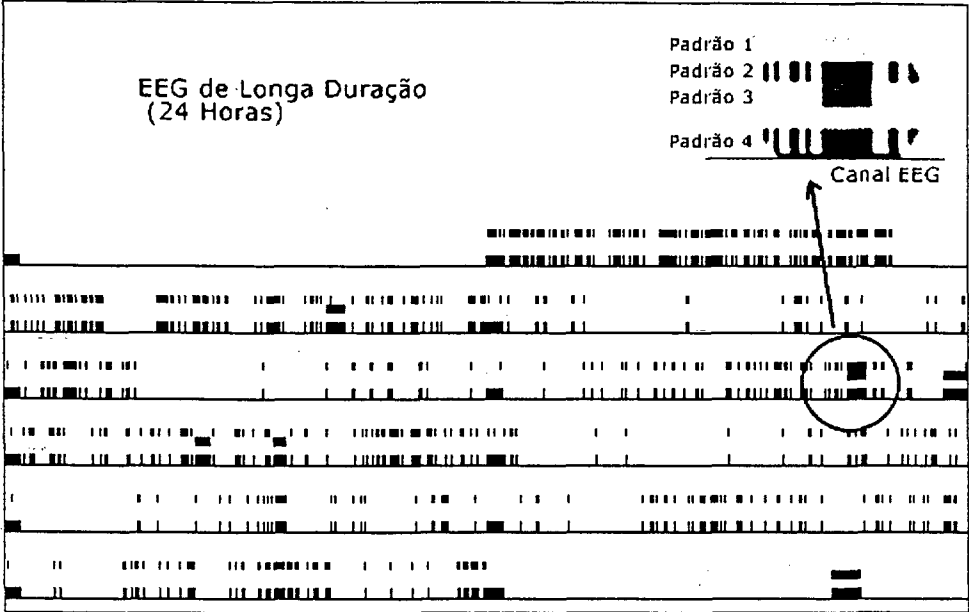
real em um arquivo de dados permitindo ao usuário uma fácil visualização dos instantes de anomalia em um estágio posterior de análise. Dessa forma, o trabalho de análise de um traçado de longa duração pode ser rapidamente efetuado pelo especialista pois ele não tem a necessidade de revisar horas de traçado. Ao invés disso o analista se ocupa inicialmente com os padrões reconhecidos pela rede neural. Uma análise profunda e mais detalhada segue-se com os resultados dessa primeira análise. A figura seguinte apresenta a tela do programa de Vídeo EEG numa aplicação real. Apenas 8 segundos da atividade EEG são vistos na tela e isso se torna uma avalanche de dados para o especialista quando são analisadas algumas horas.

Figura 6.6: Vídeo EEG digital onde o algoritmo de reconhecimento de padrões foi utilizado. (Equipamento Neuromap/Neurotec).



Nessa aplicação foram considerados apenas alguns tipos de sinais anômalos considerando algumas propriedades do sistema de aquisição de dados em uso. Foram assim usados somente os seguintes padrões repetitivos de baixa frequência descritos na tabela 6.1:

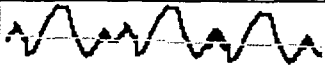
Figura 6.7: Síntese do reconhecimento de padrões feito em tempo real sobre o sinal EEG.



Obs.: O modelo acima (ainda não completamente implementado) prevê um protocolo para o usuário definindo canais EEG, tipos de padrões de classificação, características gráficas, etc. A idéia é que todo o traçado EEG possa ser inicialmente visto em algumas poucas telas e depois ampliado para uma análise específica.


Tabela 6.1: Padrões utilizados na aplicação envolvendo o vídeo EEG digital.

Padrões	Visualização	Descrição
Artefatos de eletrôdos		Mal contato entre eletrôdo e escalpo produzido principalmente pela deterioração do eletrôdo ou da pasta condutora.
Artefatos de ECG		Interferência devido ao sinal de eletrocardiograma. Tal sinal mostra uma periodicidade do complexo chamado QRS. O sinal ECG é muito maior que o sinal EEG.
Spike e Ondas		Tal tipo de padrão é visto em todas as idades mas mais frequentemente em crianças. Ele pode indicar a existência de diversas patologias e danos cerebrais (Petit mal, síndrome de Lennox-Gastaut, etc...)
Pleds		Periodic Lateralized Epileptiform Discharges (Pleds) são formas de descargas elétricas associadas com agudo dano cerebral e desarranjos metabólicos.

Ondas Trifásicas		Esse tipo de padrão foi originalmente encontrado em encefalopatias hepáticas mas tem sido associada com muitas outras formas de encefalopatias metabólicas.
------------------	---	---

A Taxa de Amostragem de Nyquist, é um pré-requisito fundamental quando se lida com amostragem de sinais dessa natureza. Em termos simples, a taxa de Nyquist estabelece que o número de observações necessárias para a correta composição e tratamento de um determinado sinal no tempo deve ser no mínimo igual ao dobro da maior frequência encontrada no sinal. Desta forma, para os sinais EEG aqui utilizados, a taxa de amostragem deve ser no mínimo de 64 Hz pois foram usados filtros para suprimir toda a atividade acima de 32Hz. O Sinal EEG é caracterizado por sua baixa frequência e frequentemente na análise do traçado EEG são usadas determinadas faixas de frequências associadas a diferentes fases de um exame e de certas patologias. A figura seguinte representa essas faixas.

Figura 6.8: Caracterização das faixas de frequência do traçado EEG.

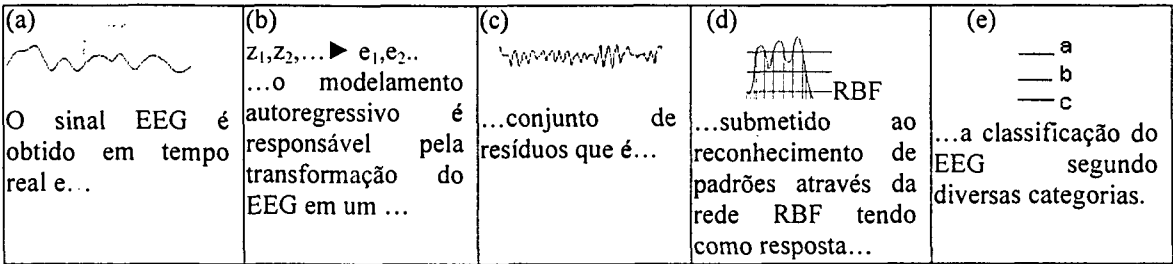


Sendo os padrões selecionados de baixa frequência, adotou-se 64 como o número de pontos para a tarefa de reconhecimento de padrões, como descrita nos capítulos anteriores. Isso habilita, segundo a taxa de Nyquist, o reconhecimento de padrões de frequências de até 32 Hz, suficientes também para o trato com as faixas Alfa, Beta, Theta e Delta. Um importante ponto a ressaltar aqui é que os artefatos de 60 Hz não podem ser captados com essa faixa de amostragem (necessita-se nesse caso de no mínimo uma taxa de amostragem de 120 Hz). Contudo, com a existência de filtros (analógicos e digitais) essas frequências podem ser seguramente suprimidas.

Os padrões de EEG selecionados, na maioria dos casos práticos de análise do sinal EEG, não são regularmente repetitivos nos moldes de muitos sistemas de manufatura. O artifício de repetitividade foi aqui inserido apenas para o cálculo de algumas medidas de *performance* em função do RL (*Run Length*). As tabelas de resultados descrevem essas medidas.

Os procedimentos ilustrados na figura 6.9 e em seguida sucintamente descritos mostram os principais passos para o desenvolvimento da metodologia de reconhecimento de padrões:

**Figura 6.9: Passos do reconhecimento dos padrões da atividade EEG.**



(a) Obtenção do Sinal EEG

Dois conjuntos de dados foram utilizados aqui como entrada considerando gráficos de 64 pontos. Primeiramente foi utilizado um conjunto de testes adicionando um nível de ruído ao conjunto de treinamento da rede neural. Um segundo conjunto, consistindo de dados reais obtidos de exames de Vídeo EEG cedidos pela Neurotec, teve seus dados de alta frequência filtrados a partir de 32Hz. Dessa forma os dados desse arquivo habilitam a simulação do reconhecimento de padrões sobre uma série temporal considerando também 64 pontos como taxa de amostragem.


Um fator que sempre se considera em problemas dessa natureza está relacionado com o número de bits do conversor analógico digital utilizado. Aqui foi empregado um conversor de 12 bits, representando basicamente que a amplitude do sinal pode ser subdividida em  $2^{12}$  níveis. Isso tem sido quase que um padrão para equipamentos de EEG digitais.

Esses traçados reais de EEG tiveram um tempo de duração variáveis (com 8 horas em média) contendo algumas discrepantes fases ao longo do tempo denominadas de "fases de ativação". Tais fases de ativação do traçado EEG descrevem na maioria das vezes a atividade de fundo e o estado do paciente durante um exame. As fases aqui consideradas foram divididas por um especialista em EEG segundo as seguintes categorias:

- Vigília: No qual o paciente permaneceu acordado e sem uma estimulação cerebral forçada;
- Sono: No qual o paciente permaneceu adormecido;
- Hiperpnéia: No qual o paciente foi estimulado através da respiração (isso é muitas vezes usado para estimular o aparecimento de sinais anômalos);
- Foto: Onde uma luz estroboscópica evoca potenciais como na hiperpnéia;
- Áudio: Onde se tem uma estimulação auditiva por meio de sons em várias frequências e amplitudes.

Também foram considerados 4 diferentes canais na condução dos experimentos, simulados um por vez, segundo o Sistema Internacional 10-20, como mostra a figura seguinte. Tais canais foram denominados nas tabelas de resultados da seção 6.4 de EEG1, EEG2, EEG3 e EEG4.

**Figura 6.10: SI 10-20.**



Obs.: No Sistema Internacional 10-20 o sinal é obtido a partir de 19 pontos com o intuito de fornecer uma boa interpretação espacial e temporal da atividade EEG. Foram aqui utilizados os canais 4 (Frontal, F3), 6 (F4), 14 (Parietal, P3) e 16 (P4). Usou-se a referência monopolar de *orelhas ligadas* onde a microvoltagem é medida em relação a um mesmo ponto (nesse caso os lóbulos da orelha). Esses canais possuem amplitudes diferentes mas com o uso do mecanismo de cálculo de resíduos, os resultados da morfologia da onda é que são evidenciados.

#### (b) Uso do Modelamento Autoregressivo



Os seguintes procedimentos descritos no capítulo 3 foram aqui utilizados para a definição do modelo autoregressivo e para o cálculo dos resíduos:

- Critérios de seleção da ordem do modelo (os respectivos nomes são encontrados no programa computacional):
  - ARORDER - Estima a ordem do modelo AR usando correlação e cumulantes;
  - MAORDER - Estima a ordem do modelo MA usando cumulantes;
- Métodos de Estimação do modelo autoregressivo:
  - ARMAQS - Estima os parâmetros ARMA por meio do algoritmo *q-slice*;
  - ARMARTS - Estima os parâmetros ARMA por meio do algoritmo de resíduos de série temporais.

O especialista foi levado a definir a fase do exame (um paralelo pode ser feito aqui com a mudança de um determinado processo de manufatura) pois essas fases são na maioria das vezes consideradas não estacionárias (alguns autores consideram tais fases também como *quase estacionárias* (Duffy e outros, 1989)).


Em um primeiro estágio foi definido apenas um modelo autoregressivo geral para todo o traçado. Nesse caso, o especialista observando a série temporal sobre controle foi levado a escolher tal modelo. Isso provou ser, como mostram as tabelas de resultados, bastante inadequado. Uma vez que a discriminação entre as fases de ativação do exame geram diferentes modelos autoregressivos, os próximos experimentos exigiram diferentes escolhas para cada um desses modelos.

### (c) Resíduos

O conjunto de resíduos gerados pelo modelamento são apresentados a rede neural. Uma importante consideração a ser feita aqui se refere ao mecanismo de deslocamento da janela de pontos nos moldes da janela deslizante (figura 5.7) aqui reproduzida:

O número de pontos, cada vez inseridos no deslocamento, naturalmente varia de aplicação para aplicação. O critério de definição desse número implica numa solução de compromisso entre a velocidade de aquisição de dados e na capacidade de processamento do reconhecimento de padrões. Em algumas aplicações (como nos casos de processos em alta frequência) não se pode ter o reconhecimento de padrões para cada ponto inserido na série temporal. Nesse caso é necessário obter conjuntos de observações que sejam capaz de reproduzir o padrão que se quer classificar, levando em consideração a fase com que esses conjuntos são apresentados a rede.

**Figura 5.7: (reprodução): Deslocamento da janela de pontos.**



Foi aqui estabelecido heurísticamente 10 como o número de pontos a serem inseridos na janela de pontos deslizantes.

#### (d) Reconhecimento de Padrões usando a rede RBF

O conjunto de treinamento e de teste da rede RBF foi construído para a identificação dos padrões descritos na tabela 6.1. Procurou-se aqui reproduzir tais padrões utilizando-se de um mecanismo não automático em detrimento da geração de equações específicas, como no caso do CEP. Sendo assim, os pontos dos padrões foram em sua maioria selecionados a partir de traçados de EEG existentes, disponibilizados pela Neurotec. Na maioria dos casos, pela insuficiência de amostras dos padrões anômalos, níveis de ruídos foram adicionadas aos padrões encontrados, expandindo esse número. Cada gráfico foi apresentado ao especialista em EEG, que reconheceu os padrões como pertencentes a tabela 6.1. No conjunto de treinamento o nível de ruído adicionado foi inferior (da ordem de 5%) mas no conjunto de teste esse nível foi incremental até 25%.

Foi usado o mesmo mecanismo de refinamento no teste da RBF descrito no capítulo anterior. No balanceamento da rede foram considerados os erros tipo I e tipo II conforme mostra a tabela seguinte:

**Tabela 6.2: Erros tipo I e tipo II para a tomada de decisão quanto ao estado do traçado EEG.**

		Situação Real	
		EEG Normal	EEG com Anomalias
Tomada de Decisão	EEG Normal	O.K. Decisão Correta	Erro II Decisão Incorreta
	EEG com Anomalias	Erro I Decisão Incorreta	O.K. Decisão Correta

O erro tipo I, resulta quando o algoritmo detecta um padrão anormal no EEG quando ele de fato não existe (ou seja, o EEG está sobre controle e o algoritmo diz que não está). O erro tipo II, é quando o algoritmo deixa de detectar um padrão de EEG anormal quando ele de fato existe. Nesse caso, o EEG não está sob controle e o algoritmo diz que está.

Como para o CEP, a seguinte medida foi considerada:

$$R_o=n_o/N_o,$$

onde:

- $o$ : classe de padrão ( $o=1$  para artefato de eletrôdo,  $o=2$  para artefato de ECG, ...);
- $n_o$ : número de padrões anormais classificados como normais;
- $N_o$ : número total de padrões da classe  $o$ .

A razão  $R_o$  foi mantida em um mesmo nível para todas as classes segundo um intervalo  $r_l \leq R_o \leq r_h$ , onde  $r_l$  e  $r_h$  são os limites inferiores e superiores da razão, respectivamente. Foram adotados  $r_l=10\%$  e  $r_h=20\%$ .

Similarmente foi definida a razão:

$$D_o=s_o/N,$$

onde:

- $s_o$  : número de padrões normais classificados como fora de controle;
- $N$  : número total de padrões sob controle.


Aqui também a razão  $D_o$  foi mantida em um mesmo nível para todas as classes segundo um intervalo  $d_l \leq D_o \leq d_h$ , onde  $d_l$  e  $d_h$  são os limites inferiores e superiores da razão, respectivamente. Foram adotados  $d_l=5\%$  e  $d_h=10\%$ .

Foram dessa forma obtidos 694 vetores representando os 5 padrões de EEG anômalos da tabela 6.1.

(e) Resultados de Classificação

A apresentação gráfica dos resultados de classificação da rede RBF em tempo real consistiu basicamente de uma janela constantemente sendo atualizada contendo a seguinte simbologia:

**Figura 6.11: Resultados gráficos de saída da rede neural em tempo real.**



Obs.: Um mecanismo de compressão desses dados nos moldes da figura 6.7 é altamente recomendável.

**6.5 Resultados e Considerações**

As seguintes tabelas mostram os resultados de classificação obtidos para toda aplicação enfocando um conjunto de dados simulados e também um conjunto de dados reais de sinal EEG.

## Resultados para dados simulados

**Tabela 6.3: Artefatos de Eletrodos.**

Ruido	Rede	ROT	RONT	ATPRL	ARLIDIX
5%	A	0.95	0.03	63.40	66.74
	B	0.87	0.05	64.30	73.91
	C	0.75	0.05	64.40	85.87
10%	A	0.87	0.12	69.17	79.58
	B	0.77	0.17	70.73	92.32
	C	0.68	0.14	69.83	102.43
15%	A	0.78	0.22	75.85	96.97
	B	0.70	0.25	77.74	110.82
	C	0.62	0.24	76.98	125.00
20%	A	0.70	0.31	84.69	120.18
	B	0.63	0.36	84.52	134.23
	C	0.54	0.35	83.81	154.03
25%	A	0.64	0.40	93.78	145.78
	B	0.57	0.44	93.56	163.03
	C	0.49	0.46	91.88	189.16

com:

Rede	Nº	Max.	Constante de	SSE (%)	Vetor de
	Neurônios		Alargamento		Entrada
A	500	1		1	Ordenado
B	600	0.75		5	Aleatório
C	700	0.5		10	Zonas

Obs.: Foram geradas 100 vetores de testes e a eles foram adicionados ruídos incrementais. Tal conjunto de teste foi apresentado para as três redes e as medidas de *performance* foram obtidas, usando o mecanismo do deslocamento da janela de pontos (*lag* de 10). O número de pontos para o reconhecimento de padrões foi estabelecido em 64, levando em consideração a taxa de amostragem de Nyquist. Pode-se perceber que, independente da rede utilizada, com o aumento do ruído, as medidas de desempenho pioram. Contudo, mesmo para o pior caso, a soma de  $R_t$  e  $R_{nt}$  indicam o reconhecimento de anomalias no vetor de artefato de eletrodo. Os resultados podem ser considerados extremamente positivos levando em consideração que a fase do gráfico (posição temporal dos pontos) é incluída.

Tabela 6.4: Ondas Trifásicas.

Ruido	Rede	ROT	RONT	ATPRL	ARLIDIX
5%	A	0.96	0.02	65.20	67.92
	B	0.84	0.06	67.90	80.83
	C	0.78	0.06	69.20	88.72
10%	A	0.86	0.11	72.99	84.47
	B	0.77	0.16	74.08	96.31
	C	0.70	0.14	76.12	108.02
15%	A	0.78	0.21	79.14	101.67
	B	0.69	0.26	81.24	117.67
	C	0.62	0.25	83.66	134.39
20%	A	0.71	0.32	87.25	122.79
	B	0.63	0.35	90.71	144.16
	C	0.56	0.34	90.96	163.67
25%	A	0.63	0.43	94.98	149.69
	B	0.57	0.45	100.43	176.64
	C	0.50	0.43	100.69	201.02

Obs.: As mesmas observações da tabela anterior são validas também aqui.

Tabela 6.5: Artefatos de Eletrocardiograma.

Ruido	Rede	ROS	RONS
5%	A	0.94	0.01
	B	0.88	0.05
	C	0.77	0.06
10%	A	0.86	0.13
	B	0.77	0.14
	C	0.70	0.16
15%	A	0.77	0.21
	B	0.71	0.24
	C	0.63	0.26
20%	A	0.70	0.32
	B	0.64	0.35
	C	0.56	0.35
25%	A	0.64	0.40
	B	0.58	0.46
	C	0.50	0.45

Obs.: A análise de *ARL* não foi feita para os artefatos de Eletrocardiograma, *Pleds* e *Spikes* devido ao caráter não cíclico desses padrões. As taxas de sucesso *ROS* (classificação correta do padrão alvo) e *RONS* (classificação do padrão como normal) diminuíram a performance com a inclusão do ruído mas os resultados podem ser considerados positivos.

Tabela 6.6: Pleds.

Ruido	Rede	ROS	RONS
5%	A	0.95	0.04
	B	0.83	0.08
	C	0.72	0.08
10%	A	0.84	0.13
	B	0.75	0.18
	C	0.65	0.16
15%	A	0.77	0.23
	B	0.68	0.28
	C	0.58	0.27
20%	A	0.69	0.34
	B	0.60	0.37
	C	0.53	0.36
25%	A	0.63	0.45
	B	0.54	0.47
	C	0.48	0.45

Tabela 6.7: Spikes.

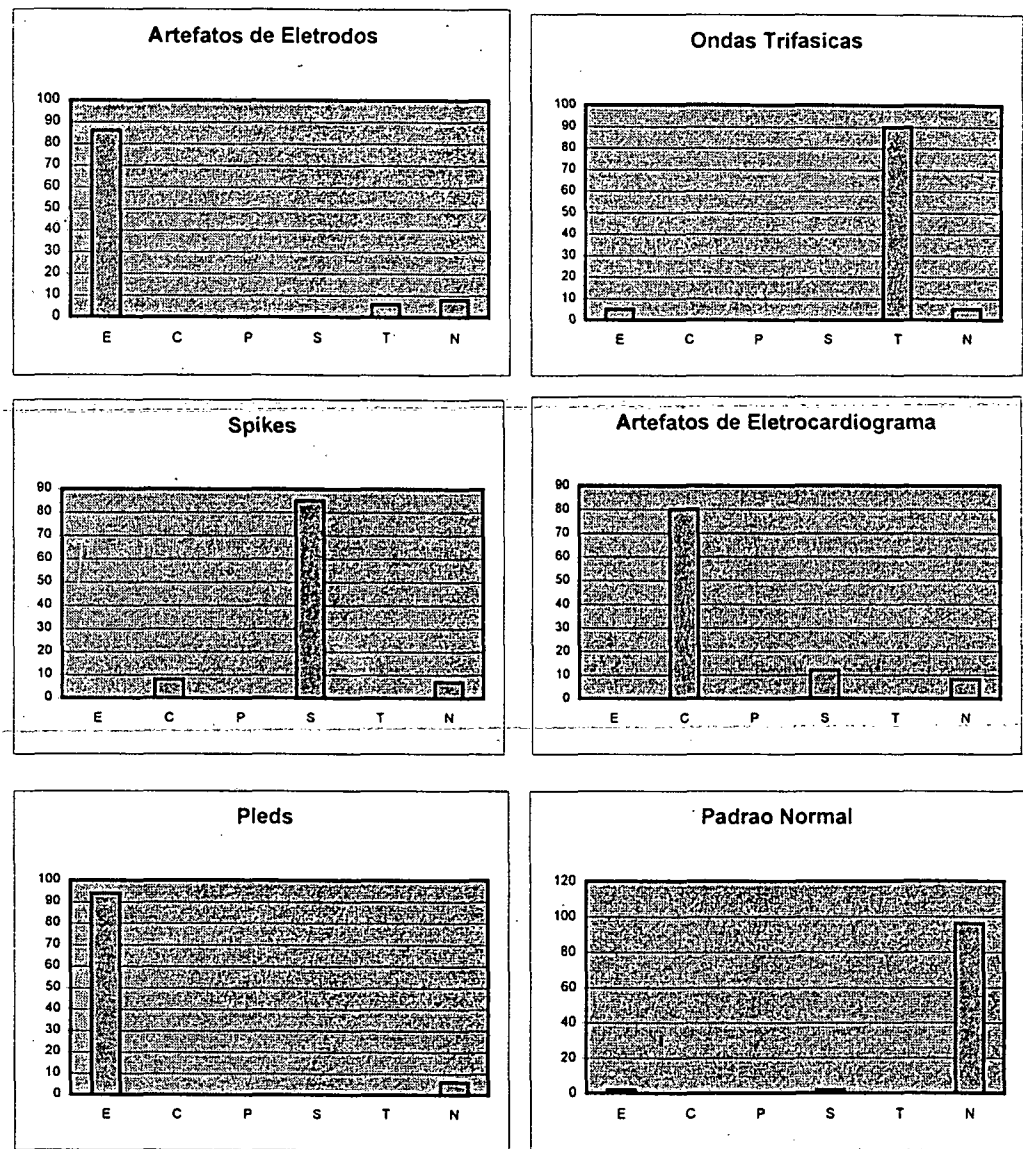
Ruido	Rede	ROS	RONS
5%	A	0.93	0.05
	B	0.87	0.06
	C	0.79	0.07
10%	A	0.85	0.13
	B	0.77	0.16
	C	0.72	0.17
15%	A	0.77	0.24
	B	0.70	0.27
	C	0.65	0.26
20%	A	0.69	0.33
	B	0.63	0.38
	C	0.57	0.36
25%	A	0.63	0.42
	B	0.57	0.48
	C	0.51	0.45

Tabela 6.8: Falsos Alarmes (%).

<i>Padrões</i>	<i>Rede A</i>	<i>Rede B</i>	<i>Rede C</i>
Artefatos de Eletrodos	1	1	0
Artefatos de ECG	0	0	1
Trifásica	3	3	4
Pleds	1	0	1
Spikes	1	1	1
<i>Total</i>	6	5	6

Obs.: Foram apresentados 100 padrões normais de teste e o erro tipo I foi avaliado. O total indica assim o nível de significância. (As redes são conforme tabela 6.3).

Figura 6.12: Histogramas dos resultados do reconhecimento de padrões.



Obs.: Foram utilizadas 700 cartas de controle divididas igualmente entre os padrões abaixo. A rede A foi utilizada (conforme tabela 6.3)



Resultados para dados de EEG

Tabela 6.9: Modelo Geral

Canal EEG	Tipos de Padrões														
	Eletrôdos			ECG			Spikes			Pleds			Trifásica		
	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.
EEG 1	264	158	06	327	206	121	6	3	3	4	2	2	0	0	0
EEG 2	13	7	6	12	6	6	94	58	38	5	3	2	3	2	1
EEG 3	12	6	6	12	7	6	6	4	2	85	53	32	6	3	3
EEG 4	12	7	5	10	6	4	8	5	3	3	2	1	116	67	49

Obs.: O especialista (Esp.) envolvido (Dr. Luiz Calistro Balestrassi), Neurologista e Neurocirurgião, conta com uma enorme casuística em EEG digital. É ele também o diretor da empresa Neurotec. O Especialista faz uma análise básica do traçado EEG e indica as regiões onde os diversos tipos de padrões ocorrem. Em seguida são apresentados os gráficos desses padrões ao especialista, em uma janela distinta, que então confirma o padrão encontrado. Pelo mecanismo de deslocamento da janela de pontos, a ocorrência de um padrão em um intervalo de tempo pode gerar várias janelas sendo confirmadas pelo especialista. Os canais de EEG foram obtidos de diferentes exames procurando evidenciar os vários tipos de padrões aqui investigados. Isso é uma limitação típica nos processos reais que tornam por vezes o treinamento da rede neural quase que impossíveis pela dificuldade de apresentação dos diversos padrões. Os padrões classificados corretamente (Cor.) e incorretamente (Inc.) usando um modelo *Geral* autoregressivo para o cálculo de resíduos não apresentou bons resultados de classificação. Isso porque as diversas fases de ativação apresentam uma certa não estacionaridade com o tempo. O Canal EEG 1 apresentou problemas com os eletrôdos ao final do traçado e também com a presença de muitos artefatos de eletrocardiograma. O modelo *Geral* considerou a soma de padrões encontrados em todas as fases descritas nas tabelas seguintes.

Tabela 6.10: Vigília

Canal EEG	Tipos de Padrões														
	Eletrôdos			ECG			Spikes			Pleds			Trifásica		
	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.
EEG 1	68	59	9	94	80	14	0	0	0	0	0	0	0	0	0
EEG 2	3	2	1	2	1	1	0	0	0	1	1	0	0	0	0
EEG 3	1	0	1	2	2	0	0	0	0	1	0	1	1	0	1
EEG 4	1	1	0	2	1	1	1	0	1	0	0	0	3	2	1

Obs.: O modelo de *Vigília*, contendo basicamente padrões de artefatos de eletrôdos e artefatos de eletrocardiograma respondeu positivamente na tarefa de classificações de padrões.

Tabela 6.11: Hiperpnéia

Canal EEG	Tipos de Padrões														
	Eletrôdos			ECG			Spikes			Pleds			Trifásica		
	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.
EEG 1	0	0	0	0	0	0	3	2	1	2	1	1	0	0	0
EEG 2	3	2	1	3	2	1	34	29	5	2	2	0	1	1	0
EEG 3	3	2	1	4	3	1	2	1	1	23	19	4	1	0	1
EEG 4	3	2	1	1	1	0	3	1	2	1	1	0	45	37	8

Obs.: Durante a fase de ativação da Hiperpnéia, os potenciais anômalos de *Spikes*, *Pleds* e ondas trifásicas foram evidenciados com também uma boa resposta pela rede.

Tabela 6.12: Foto Estímulo

Canal EEG	Tipos de Padrões														
	Eletrôdos			ECG			Spikes			Pleds			Trifásica		
	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.
EEG 1	0	0	0	0	0	0	1	1	0	1	1	0	0	0	0
EEG 2	4	3	1	3	0	3	15	11	4	1	0	1	1	0	1
EEG 3	3	3	0	2	1	1	3	1	2	34	27	7	1	0	1
EEG 4	3	0	3	3	2	1	1	1	0	2	1	1	28	22	6

Tabela 6.13: Áudio Estímulo

Canal EEG	Tipos de Padrões														
	Eletrôdos			ECG			Spikes			Pleds			Trifásica		
	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.
EEG 1	0	0	0	0	0	0	2	2	0	1	1	0	0	0	0
EEG 2	2	1	1	2	1	1	45	40	5	1	0	1	1	1	0
EEG 3	2	1	1	3	2	1	1	1	0	25	19	6	2	1	1
EEG 4	2	0	2	2	1	1	2	1	1	0	0	0	35	28	7

Tabela 6.14: Sono

Canal EEG	Tipos de Padrões														
	Eletrôdos			ECG			Spikes			Pleds			Trifásica		
	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.	sp.	or.	nc.
EEG 1	196	178	18	233	214	19	0	0	0	0	0	0	0	0	0
EEG 2	1	1	0	2	1	1	0	0	0	0	0	0	0	0	0
EEG 3	1	1	0	1	1	0	0	0	0	2	2	0	1	1	0
EEG 4	3	2	1	2	1	1	1	1	0	0	0	0	5	4	1

Obs.: O modelo utilizado para o sono teve o melhor desempenho pois o traçado se manteve mais homogêneo com o tempo. O canal EEG1 teve problemas de artefatos de eletrôdos e de eletrocardiograma durante essa fase.


### Considerações Finais:

As seguintes considerações merecem ser destacadas para essa aplicação:

- Muitas corretas classificações foram apresentadas ao especialista que falhou em identificá-las numa análise preliminar do exame. Isso mostrou que a rede foi capaz de responder bem a tarefa de classificação de padrões e que potencialmente ela representa uma fonte de auxílio para a técnico eletrencefalografista.
- A determinação das fases de ativação do traçado EEG (Vigília, Sono, ...) é um natural aprimoramento que se deve buscar na metodologia para a sua completa automatização. Isso pode ser feito analisando-se somente a atividade de fundo de um traçado EEG e uma rede específica poderia ser utilizada para isso.
- O aumento do número de padrões de EEG a serem classificados devem ser incluídos nesse tipo de aplicação. Um protocolo de seleção do padrão que se quer identificar também auxiliaria em muito o eletrencefalografista. Muitas vezes, pelo tipo de patologia suspeita, o médico tem em mente um certo número de padrões em detrimento de outros.
- O paralelismo de redes analisando vários canais é um aprimoramento natural que deve ocorrer com o estágio atual do avanço tecnológico. Isso habilitaria a investigação de todos os canais EEG do SI 10-20 simultaneamente.
- O esboço de um sistema especialista para a definição de patologias baseadas no sinal EEG, levando em consideração a imprecisão do Sinal EEG é mostrado no artigo em anexo (*Números Difusos na Análise do Sinal EEG*).
- Diferentes aplicações podem ser desenvolvidas usando essa mesma metodologia. Sinais cardíacos, de potenciais evocados, além de inúmeros processos de manufatura anteriormente citados fornecem uma gama de possibilidades para o futuro. De imediato, a Neurotec tem um grande interesse na inserção da característica de

reconhecimento de padrões em seu Vídeo EEG Digital e no Monitor Cerebral. Nos sistemas de Monitoramento Cerebral, como nos casos de cirurgia cardíaca, onde o sinal EEG precisa ser visto em tempo real, a rede neural é utilizada para identificar padrões anômalos e um sistema computadorizado deve emitir um sinal de advertência sempre que isso ocorre. Os resultados devem ser comparados com os resultados clássicos dos Descritores de Hjorth, que utilizam os conceitos de Atividade, Complexidade e Mobilidade, para desempenhar essa mesma tarefa. A figura seguinte apresenta tais descritores.

Figura 6.13: Monitor cerebral mostrando os Descritores de Hjorth (Equipamento Neuromap/Neurotec).



## **Capítulo 7 – Conclusão**

---

### **7.1 Introdução**

O presente capítulo revisa os importantes pontos que nortearam os rumos dessa pesquisa. Na seção 7.2 o desenvolvimento do trabalho com suas contribuições ao longo dos capítulos é sumarizado. A seção 7.3 apresenta algumas discussões, limitações e futuros naturais desenvolvimentos. Na seção 7.4 as principais conclusões e contribuições do trabalho são descritas.

### **7.2 Desenvolvimento e contribuições**

#### Introdução

O principal problema abordado nessa pesquisa consistiu na implementação de uma metodologia eficaz de Controle Estatístico de Processos, notadamente uma ótima ferramenta no trato com variações, em processos serialmente correlacionados sob o regime de tempo real.

Foi assim desenvolvido um sistema híbrido de reconhecimento de padrões baseado em modelamento de séries temporais e no uso de redes neurais artificiais para os dados de uma carta de CEP sob o regime de tempo real. Tal sistema foi capaz de identificar padrões não aleatórios de variação em uma série temporal. O sistema foi direcionado primeiramente a processos de manufatura automatizados onde os dados fatalmente apresentam uma correlação serial que impede a aplicação direta das cartas de controle (pois os dados não são *iid*). Uma aplicação correlata abordando sinais EEG foi avaliada apresentando um grande poder de generalização da metodologia.

#### Revisão

Foram abordados os principais aspectos do CEP no enfoque dessa pesquisa, revisando o que tem sido feito e publicado nos principais periódicos da área. Foi

abordada a escolha de padrões de CEP (tendência, variações sistemáticas, ciclos, misturas e padrões de estratificação) sobre os quais a metodologia avaliou os seus resultados. Algumas deficiências das regras suplementares (como por exemplo, o aumento do erro tipo II) que são usadas convencionalmente no CEP foram também discutidas.

Foram consideradas as peculiaridades do CEP em tempo real, abordando sistemas automatizados de manufatura e diversos outros processos que atendem a gama de aplicações para a metodologia. Nesses sistemas, o tamanho unitário da amostra para as cartas de controle, leva certamente a problemas de correlação serial e contrasta com a suposição dos subgrupos racionais das cartas de controle que efetuam as medidas tipicamente com observações periódicas e com tamanho de amostras maior que 1. Gerando um conjunto de resíduos a partir de um modelamento estocástico (tipicamente autoregressivo), tal conjunto de resíduos será *iid* se o processo estiver sobre controle e então uma carta de controle pode ser empregada. Mudanças no nível de dispersão dos dados originais podem ser então capturadas pelas cartas de controle agindo sobre o conjunto de resíduos.

Foi também avaliado um enfoque da inteligência artificial no CEP contextualizando tipos de agentes racionais, ambientes, regra *if-then-else* e "Janelas de Qualidade".

Foi introduzido o reconhecimento neural de padrões das cartas de CEP como uma forma alternativa de usar as cartas de CEP em tempo real. A literatura sobre isso não é tão vasta e alguns trabalhos foram investigados e definiram os rumos da pesquisa. Foram assim listadas as características e limitações dos trabalhos de Swift (1987), Cheng (1989), Hwang (1992), Guo e Dooley (1992), Lucy-Bouler (1991) e Tontini (1995).

### Séries Temporais

Foram descritos os procedimentos adotados para a obtenção dos resíduos em tempo real. Modelos de séries temporais foram usados para a filtragem de sinais auto-

correlacionados em processos sob o regime de tempo real. Os resíduos gerados dessa filtragem, agora *iid*, foram usados no controle estatístico de processos. A metodologia proposta consistiu em usar um método automático (com pouca intervenção humana) no sentido de escolher um modelo que represente consistentemente a estrutura de autocorrelação do processo. Depois da escolha do modelo, pode-se obter o conjunto de resíduos para a investigação dos padrões por meio do CEP. De uma forma geral, o modelamento de séries temporais exige quase sempre a presença de um especialista e também de programas dedicados onde um conjunto de testes de hipóteses é avaliado para a escolha final do modelo. Isso inviabiliza o grande escopo de aplicações em tempo real devido ao caráter dinâmico da obtenção dos dados.

O caso univariado foi apresentado e exemplificado abordando a implementação das metodologias padrões de modelamento de séries temporais e considerando diversas novas alternativas desenvolvidas recentemente. Critérios de seleção da ordem do modelo foram definidos (ARORDER e MAORDER), assim como métodos de estimação do modelo autoregressivo (ARMAQS e ARMARTS).

O algoritmo implementado foi comparado com resultados já sedimentados na literatura. Foram investigadas algumas séries temporais com várias ordens de parâmetros bem como diferentes valores dos coeficientes autoregressivos e de médias móveis. Foram testados diversos procedimentos considerando a exatidão dos resultados em relação as seguintes séries clássicas: série de temperaturas e séries de filmes metálicos (Box e Luceño, 1998), série de diâmetros (Montgomery e Friedman, 1986). Foram comprovados os mesmos resultados clássicos definidos pelos autores.

### Redes Neurais Artificiais

Foi feita uma breve revisão sobre as redes neurais artificiais e listadas as suas potenciais características que a habilitam para a tarefa de reconhecimento de padrão de CEP. Tais características são:

- Podem aprender de exemplos e adaptar-se a novas situações;

- São robustas (podem abstrair informações de dados com ruído, incompletos ou não precisos);
- Podem generalizar a partir de exemplos (podem prover soluções corretas para dados similares, não vistos no treinamento);
- Podem construir soluções rapidamente sem muito domínio do conhecimento do processo;
- Podem aproximar qualquer função multivariada complexa (mal definida ou desconhecida) e formar uma decisão de classificação a partir do reconhecimento de padrões discriminantes;
- São computacionalmente eficientes (tem a velocidade para operar em tempo real).

Para se ter uma boa visão das redes neurais foi útil descrevê-las em relação aos sistemas especialistas e aos métodos estatísticos.

Uma estrutura comum em basicamente todas as RNs é o neurônio. Diferenças existem entre arquiteturas de redes e paradigmas de aprendizagem, mas desde que RNs são tipicamente compostas de camadas de neurônios foi oportuno descrever primeiramente esse conceito básico. Foram também tecidas considerações com respeito ao aprendizado, a topologia e a classificação de padrões das redes neurais. Existem essencialmente três fatores que foram considerados para a seleção da rede neural. O primeiro é como os neurônios processam as informações. Esse fator enfoca a determinação do somatório e da função de ativação. Um outro é como os pesos das conexões são modificados. Isso é determinado pelo tipo de paradigma de treinamento escolhido. O último fator consiste na determinação da maneira com que os neurônios da rede são conectados, definindo a arquitetura ou topologia da rede. Em muitas circunstâncias, como nesse trabalho, esses fatores são influenciados pela definição do problema em questão.

Foram citados 21 casos comparando RNs com outras técnicas, sobre vários domínios, onde as RNs superaram essas técnicas em 18 casos. As RNs tiveram bons resultados em relação aos métodos estatísticos clássicos pois sua natureza não



paramétrica não necessitou assumir considerações sobre a forma da distribuição dos dados.

### Reconhecimento Neural de Padrões em CEP

Alguns trabalhos comparando o resultado do reconhecimento de padrões de CEP usando técnicas convencionais, sistemas especialistas e redes neurais artificiais foram apresentados. Muito embora não tenha sido utilizado um mesmo banco de dados, a condução dos experimentos tenha sido diferente, os tipos de padrões também diferentes, os casos práticos não serem investigados, etc.... tais trabalhos mostraram resultados destacando um futuro promissor para os sistemas baseados em redes neurais. São eles: Pham e Oztemel (1994), Tontini (1995), Guo e Dooley (1992), Smith (1994), Cook (1998), Hwarng e Hubele (1994). Um fato que se pode perceber é que a escolha da arquitetura da rede neural em si não é um grande problema para aplicações como estas. As seguintes redes foram assim simuladas: *Backpropagation*, LVQ, RBF, ARTMAP e Fuzzy-ARTMAP. Os resultados gerais alcançados usando a rede Fuzzy-ARTMAP (com as limitações intrínsecas de um pacote computacional não flexível) foram superiores aos resultados alcançados pela rede RBF; contudo, o desenvolvimento de toda a metodologia em tempo real ficou comprometido devido a sua dificuldade de implementação.

Foi apresentada toda a construção do banco de dados dos padrões de treinamento e teste das redes neurais. Para tanto, os seguintes procedimentos foram desenvolvidos:

- Avaliação e determinação dos parâmetros dos padrões: onde os valores dos parâmetros usados para as diversas classes de padrões foram obtidos;
- Triagem preliminar: foi usada uma rede neural, treinada preliminarmente sem bons resultados, para eliminar padrões de treinamento que foram contraditórios;
- Avaliação do erro tipo II: tal erro existe quando o algoritmo deixa de detectar um padrão não natural quando ele de fato existe. Nesse caso, o processo não

está sob controle e o algoritmo diz que está. Um mecanismo de balanceamento da rede foi desenvolvido para avaliar tal erro;

- Avaliação do erro tipo I: tal erro resulta quando o algoritmo detecta um padrão não natural qualquer quando ele de fato não existe. Ou seja, o processo está sobre controle e o algoritmo diz que não está. Como no item anterior, um mecanismo foi desenvolvido;
- Foi obtido um bom balanceamento de padrões para a entrada das redes neurais e sobretudo os padrões não mostraram ambigüidade no sentido de fornecer uma boa indicação de causas assinaláveis de variação. Foram dessa forma obtidos 489 vetores representando as 6 classes de padrões de CEP. Foi também definido o número de observações de cada vetor representando a carta de controle, denominado de "janela de CEP". Tal janela foi definida de acordo com a probabilidade teórica de se cometer o erro tipo I para cada padrão não natural quando o processo está sobre controle;
- Os conjuntos de treinamento e de teste para as redes neurais foram construídos separadamente devido a certas peculiaridades:
  - Conjunto de treinamento:
    - Geração de amostras do processo sobre controle: alguns procedimentos de teste da normalidade foram construídos no sentido de limitar a existência de pontos fora dos limites de controle. Tais testes se resumem nas cartas de Shewhart para pontos individuais, no uso da estatística envolvendo a soma dos quadrados dos desvios e também da carta CUSUM;
    - Geração de amostras de padrões não aleatórios para treinamento: foram implementadas as equações descritas no anexo A. Tais equações apresentam um conjunto de vetores de entrada para as redes neurais com as suas respectivas respostas. Para um melhor desempenho na tarefa de classificação das redes, as seis classes de padrões foram subdivididas em classes menores discriminando também os valores dos parâmetros para cada classe;
  - Conjunto de teste: uma importante diferença entre os padrões de treinamento e os padrões de teste na construção do banco de dados se refere ao modo de

inserção de observações no vetor que representa a carta de controle. Foi desenvolvido um mecanismo de deslocamento da janela de pontos para a simulação de processos reais onde os padrões não aleatórios vão surgindo com o tempo. Por meio desse mecanismo, foi também obtido o *ARL* e diversas medidas de *performance* da rede.

Um tratamento especial foi mostrado para alguns tipos especiais de padrões abordando problema da invariância para padrões cíclicos e o deslocamento da média.

Os experimentos de Tontini (1995) foram aqui repetidos com alguma limitação. utilizando a rede neural Fuzzy-ARTMAP através do programa *The ART Galery*. Os principais resultados desse experimento foram:

- Aplicados como entrada das redes neurais sem nenhum tipo de pré-processamento, as cartas de controle do banco de dados não tiveram uma satisfatória taxa de acertos em termos de reconhecimento de padrões. Foram então inseridos algumas simples estatísticas como pré-processamento que serviram de entrada para a rede Fuzzy-ARTMAP;
- Os resultados alcançados com a rede Fuzzy-ARTMAP apesar de promissores não foram conclusivos devido a dificuldade de avaliação das medidas de desempenho. Toda a análise envolvendo o cálculo do *ARL* e medidas derivadas não foi possível devido as limitações intrínsecas do programa *The ART Gallery*, não disponibilizando um código computacional compilável;
- Algumas vantagens da rede Fuzzy-ARTMAP claramente observadas foram: (i) adaptar-se a mudanças no processo e *aprender* com problemas e exemplos ocorridos durante sua operação, mesmo que esses exemplos não tenham sido estruturados, (ii) tratar relações não lineares e (iii) tratar problemas difusos, comuns de se encontrar na vida real;

A função de base radial (RBFN) foi rapidamente descrita com vistas ao reconhecimento de padrões das cartas de CEP abordando os seus seguintes aspectos: (i)

arquitetura da rede, (ii) neurodinâmica da rede, (iii) operação da rede, (iv) treinamento da camada de padrões e (v) determinação das larguras da função de base radial.

Algumas importantes vantagens observadas nessa rede foram: (i) Seu treinamento é bastante rápido pois a localização dos centros pode ser determinada usando aprendizagem supervisionada e essa representação local assegura que somente uns poucos neurônios da camadas de padrões respondem a uma dada entrada. Existe também uma redução no tempo computacional requerido pelo aprendizado supervisionado desde que somente uma camada de pesos precisa ser atualizada. (ii) As RBFNs também provêem uma melhor fronteira de decisão do que as redes baseadas em *Backpropagation* pois a sua representação localizada do espaço de entrada resulta em um melhor particionamento do espaço de decisão. (iii) Elas tem a habilidade de reduzir erros de extrapolação e de prover informações para novos padrões no espaço de entrada não cobertos pelos dados de treinamento. As funções de ativações dos neurônios são auto limitantes nas regiões que elas formam, as quais elas incorporam a informação de distância. Isso facilita a classificação de novos padrões de acordo com a sua proximidade ao conjunto de treinamento. Isso habilita a rede em indicar que um padrão original de entrada está distante do conjunto de treinamento embora ainda efetuando a mais plausível classificação. (iv) A RBFN generaliza extremamente bem mesmo em tarefas complicadas e o desempenho da rede não é muito prejudicada pelo não balanceamento das quantidades do conjunto de treinamento disponível para as diferentes categorias de padrões. (v) As RBFNs provêem uma excelente aproximação e representam uma técnica robusta para um grande número de problemas tais como modelamento de dados.

As RBFNs tem uma desvantagem potencial: desde que a fase inicial de treinamento é não supervisionada (ou auto organizada) para o agrupamento de centros, existe a possibilidade de perda de algumas informações discriminantes (Haykin, 1994).

Um conjunto extenso de simulações foi necessário para se testar a capacidade da rede em detectar os diversos padrões não aleatórios das cartas de controle. Nesse sentido, o algoritmo da rede neural foi repetidamente aplicado às seqüências de dados e

quando o padrão de interesse foi detectado, o RL (*run length* - número de pontos até a detecção do padrão não natural) foi obtido. Com um número considerável de RLs foi calculado o *ARL*. Assim, no teste do desempenho da rede neural, uma medida foi avaliada em termos de ambos os erros (tipo I e tipo II), isto é, tanto os padrões não aleatórios quanto os padrões aleatórios devem ser usados para testar e computar essa medida. Um sistema de reconhecimento de padrões não pode ser garantidamente útil na prática se ele não considera ambos os erros. Foram computados assim as seguintes medidas:

- $R_t$  e *ROS* - Percentagem de seqüências onde o alvo padrão foi obtido;
- $R_{nt}$  e *RONS* - Percentagem de seqüências onde o alvo padrão não foi obtido;
- *ARL<sub>t</sub>* - *ARL* quando o alvo padrão foi obtido;
- *ARL<sub>tx</sub>* - *ARL* considerando toda a seqüência de dados.

As tabelas, gráficos e resultados da classificação de padrões para o problema do CEP podem ser melhor vistos na seção 5.7. Tais resultados podem ser considerados positivos.

### Aplicação EEG

Uma aplicação foi desenvolvida tendo em vista a generalização da metodologia proposta. O problema do reconhecimento de padrões dos sinais EEG foi então abordado e teve positivos resultados.

Foram discutidos rapidamente alguns aspectos da atividade EEG e sua caracterização quanto a uma série temporal nos moldes de um sistema de manufatura automático. O equipamento de Vídeo EEG da empresa Neurotec foi apresentado e foi feita a descrição do problema a ser abordado. Dois problemas comumente encontrados na análise da atividade EEG foram considerados nessa aplicação. Ambos os problemas estão relacionados com a detecção de sinais anômalos ao sinal EEG.

O primeiro problema consistiu na identificação e caracterização de sinais anômalos de origem patológica tais como *spikes*, descargas epiléticas, certas

morfologias de ondas, etc.. Um segundo caso consistiu na identificação de artefatos, que são comumente sinais representando movimentos musculares ou interferências não patológicas que invariavelmente prejudicam a análise do traçado EEG.

A identificação das anomalias acima, resultantes do reconhecimento de padrões feito com as redes neurais, foi armazenada em tempo real em um arquivo de dados permitindo ao usuário uma fácil visualização dos instantes de anomalia em um estágio posterior de análise. Dessa forma, o trabalho de análise de um traçado de longa duração pode ser rapidamente efetuado pelo especialista pois ele não tem a necessidade de revisar horas de traçado. Ao invés disso o analista se ocupa inicialmente com os padrões reconhecidos pela rede neural. Uma análise profunda e mais detalhada segue-se com os resultados dessa primeira análise. Essa é uma contribuição fundamental para esse tipo de exame.

Os seguintes tipos de padrões foram assim definidos e identificados: Artefatos de eletrôdos, artefatos de ECG, *Spike*, *Pleds* e ondas trifásicas. A taxa de amostragem de Nyquist, número de bits de um conversor A/D e outros aspectos de aquisições de dados foram abordados. Os seguintes passos do desenvolvimento foram evidenciados:

- Obtenção do sinal EEG: Dois conjuntos de dados foram utilizados como entrada do sistema considerando gráficos de 64 pontos (devido a taxa de Nyquist). Primeiramente foi utilizado um conjunto de testes adicionando um nível de ruído ao conjunto de treinamento da rede neural. Um segundo conjunto, consistindo de dados reais obtidos de exames de vídeo EEG, teve seus dados de alta frequência filtrados a partir de 32Hz. Dessa forma os dados desse arquivo habilitaram a simulação do reconhecimento de padrões sobre uma série temporal considerando também 64 pontos como taxa de amostragem. Foram consideradas também as fases de ativação do traçado EEG, como vigília, sono, áudio estímulo, etc...;
- Uso do modelamento autoregressivo: Um especialista foi levado a definir as fases do exame pois tais fases são na maioria consideradas não estacionárias.

Foram assim selecionadas a ordem do modelo e o método de estimação do modelo autoregressivo;

- Resíduos: O conjunto de resíduos gerados pelo modelamento foram apresentados a rede neural usando o mecanismo da janela de deslocamento;
- Reconhecimento de Padrões usando a rede RBF: O conjunto de treinamento e de teste da rede RBF foi construído para a identificação dos diversos padrões EEG. Procurou-se aqui reproduzir tais padrões utilizando-se de um mecanismo não automático em detrimento da geração de equações específicas, como no caso do CEP. Sendo assim, os pontos dos padrões foram em sua maioria selecionados a partir de traçados de EEG existentes, disponibilizados pela Neurotec. Na maioria dos casos, pela insuficiência de amostras dos padrões anômalos, níveis de ruídos foram adicionadas aos padrões encontrados, expandindo esse número. Cada gráfico foi apresentado ao especialista em EEG, que reconheceu os diversos tipos padrões. No conjunto de treinamento o nível de ruído adicionado foi inferior (da ordem de 5%) mas no conjunto de teste esse nível foi incremental até 25%. Foi usado um mecanismo para o balanceamento da rede considerando os erros tipo I e tipo II;

Foram gerados diversas tabelas e gráficos com os resultados de classificação do sinal EEG. Tais resultados foram descritos na seção 6.5. e são certamente positivos. Eles foram divididos em resultados para dados simulados e resultados para dados reais;

### **7.3 Discussões e Desenvolvimentos Futuros**

Alguns tópicos sempre vieram a tona durante essa pesquisa e são rapidamente considerados a seguir.

#### Regressão Múltipla e Redes Neurais

Sob um cuidadoso exame, pode-se encontrar uma forte similaridade entre a Análise de Regressão Múltipla (ARM) e a teoria de computação das Redes Neurais (RN) na tarefa de resoluções de problemas. A ARM procura resolver um dado problema

através da estimação de parâmetros das variáveis independentes de um modelo e subsequentemente obtém valores para as variáveis dependentes através da equação da regressão. Usando RNs uma rede é treinada para resolver um problema através da adaptação dos pesos de suas conexões por meio de um processo iterativo de treinamento. Em ambos os casos, um conjunto de dados (de treinamento) deve ser providenciado no sentido de se estimar os parâmetros ou adaptar os pesos das conexões.

Um modelo para a regressão múltipla que descreve uma variável dependente  $y$  (ou resposta) para  $k$  independentes variáveis pode ser definido como segue:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i \quad i = 1, 2, \dots, n$$

onde

- $y_i$  : a  $i$ -ésima observação da variável dependente  $y$ ,
- $x_{ij}$  : a  $i$ -ésima observação da variável independente  $x_j$ ,
- $\beta_j$  : o  $j$ -ésimo parâmetro,  $j=0, 1, \dots, k$ ,
- $\varepsilon_i$  : erro aleatório não correlacionado,  $N(0, \sigma^2)$ .

O objetivo principal do modelo acima é estimar todos os parâmetros  $\beta_j$  apropriadamente minimizando a soma do erro quadrático do conjunto dado de observações. Isso pode ser matematicamente expresso pela soma  $\text{MIN} \sum (y_i - \bar{y}_i)^2$ .

Quando comparados, o interessante relacionamento entre o modelo de regressão múltipla e as redes neurais podem ser observados:

- $y_i$  e  $\bar{y}_i$ , são respectivamente equivalentes ao  $i$ -ésimo alvo e à saída computada da rede neural quando o padrão  $i$  é apresentado;
- as observações  $x_{ij}$  correspondem aos valores da camada de entrada da rede neural;
- os parâmetros  $\beta_j$  são similares aos pesos das conexões das redes neurais.

Os parâmetros na ARM são estimados utilizando um conjunto de equações normais enquanto os pesos das conexões da RN são adaptados usando uma regra de



aprendizagem que procura minimizar a diferença entre os valores computados e os valores alvos.

### Conjuntos Difusos e Redes Neurais

Em problemas de reconhecimento de padrões, freqüentemente são encontradas situações onde a fronteira de classificação entre as classes não é suficientemente clara e a decisão quanto a classificação de um padrão torna-se difícil. Uma das teorias matemáticas que é adequada para o tratamento dessas situações é a teoria de conjuntos difusos.

Na tarefa de reconhecimento de padrões das cartas de controle, é bem conhecido que existe uma confusão entre determinados tipos de padrões. Como por exemplo, um padrão cíclico pode (com um certo nível de ruído) ser facilmente confundido com um padrão de mistura. Uma função de pertinência poderia ser usada para estimar o grau no qual um padrão pertence a cada classe de padrão. Assim, no pré-processamento dos dados, essa função de pertinência poderia de alguma maneira ser incorporada à entrada da rede neural. Por outro lado, as saídas das redes neurais são valores das funções de ativação que representam cada classe de padrões. Esses valores na verdade servem como medidas de similaridade entre dados observados e as diversas classes de padrões. A representação da saída produzida por muitas redes neurais lembra claramente a função de pertinência da teoria de conjuntos difusos.

Esboçando um meio de representação dos dados usando a teoria de conjuntos difusos, seja  $f_j$ , com  $j=1,2,\dots,n$ , definindo as características dos padrões de uma carta de controle. Para o padrão  $i$ , seja  $M_{f_j}^i$  o valor da função de pertinência do padrão  $i$  no conjunto difuso com a característica  $f_j$ , (ou interpretado como "o padrão  $i$  possui uma certa característica que pertence ao conjunto difuso com a característica  $f_j$ "). Seja  $M_{o_k}^i$  o valor da função de pertinência do padrão  $i$  no conjunto difuso para a classe  $o_k$ ,  $k = 1, 2, \dots, q$ . Assim, cada padrão  $i$  pode ser representado pelo par de valores de pertinência:

$$V^i = (\underline{F}^i, \underline{Q}^i)$$

Onde  $\underline{F}^i = [M_{f_1}^i, M_{f_2}^i, \dots, M_{f_n}^i]$  e  $\underline{Q}^i = [M_{o_1}^i, M_{o_2}^i, \dots, M_{o_q}^i]$ .

Para um conjunto de  $p$  vetores de treinamento, uma correspondente matriz de pertinência poderia consistir de  $p$  vetores  $V^i, i = 1, 2, \dots, p$ . Essa matriz então poderia ser usada como a entrada de uma rede neural associada ao seu tipo de padrão para o treinamento supervisionado.

A incorporação da teoria de conjuntos difusos no contexto dessa aplicação requer uma maior mudança no modo como os dados são pré-processados assim como na sua representação para as camadas de entrada e de saída das redes neurais. É esperado uma maior complexidade na implementação desse conceito em função da especificação da função de pertinência. Na verdade, a definição da função de pertinência é subjetiva em sua natureza e pode-se dizer, uma das maiores controvérsias usando conjunto difusos.

Uma quantidade relevante de trabalhos tem mostrado evidência de que a combinação de redes neurais com conjuntos difusos tem sido uma poderosa ferramenta na resolução de problemas complexos ou de complexa definição. A tabela abaixo descreve algumas das características dos conjuntos difusos e das redes neurais para resolver um problema genérico:

**Tabela 7.1: Comparação das características da aproximação de um problema usando conjuntos difusos e redes neurais (Kong & Kosko, 1990).**

Característica	Conjuntos Difusos	Redes Neurais
Execução	Conhecimento estrutural é disponível	Conjunto de dados é disponível
Requisitos dos dados	Um pequeno número de amostras de conjuntos difusos	Um grande número de amostras
Mapeamento e treinamento	Regras de inferência	Algoritmos de aprendizagem
Função de ativação	Não	Sim
Computação	Pouca	Muita

Genericamente falando, tanto os conjuntos difusos quanto as redes neurais procuram resolver o problema como uma “caixa preta” sem o requerimento de complicados modelamentos matemáticos. Essa “caixa preta” é capaz de associar certas entradas a certas saídas desejadas.

### Limitações do Trabalho

Existem algumas limitações no trabalho que podem e devem ser superadas futuramente. Considerando as redes neurais percebeu-se o seguinte:

- A *performance* da rede RBF está sujeita a uma boa seleção do conjunto de treinamento;
- O desempenho da rede é também limitada quando alguns padrões estão contaminados com um alto nível de ruído. Isso é causado pela incorporação de padrões que podem ser confundidos por natureza com outros tipos de padrões;
- A rede RBF pode somente lidar com uma janela de dados que é fixa. Para se usar todas as observações disponíveis mais eficientemente, janelas de pontos variáveis devem ser provavelmente consideradas.

Considerando o trabalho simulado as seguintes limitações foram impostas ao processo não constituindo um grande problema para a sua implementação em casos reais.

- O processo precisa estar sobre controle na definição do modelo autoregressivo: Um técnico é levado a ajudar na definição do estado do processo. Isso foi usado para se evitar o uso de redes neurais não supervisionadas. Isso certamente consiste em um tópico de pesquisa;
- A suposição da normalidade foi assumida no processo: A definição da suposição de normalidade é comumente utilizada na análise do CEP. O Teorema Central do Limite procura justificar a adoção dessa medida, contudo numa pesquisa futura uma melhor adequação das distribuições de probabilidade deverá ser investigada;
- As amostras são obtidas em intervalos regulares de tempo: Isso é comumente uma prática na grande maioria dos conversores analógicos digitais, não

constituindo uma limitação também para a maioria dos processos automatizados.

### Desenvolvimentos Futuros

Além da busca pela supressão das limitações anteriores, os futuros naturais desenvolvimentos dessa pesquisa estão listados a seguir:

- O uso de algoritmos genéticos na tentativa de determinar o número ótimo de neurônios para a rede RBF, ao invés de um método experimental (considerando sistematicamente a tentativa e erro), pode aumentar a *performance* da rede;
- O uso do tamanho da janela de pontos como variável pode representar melhor os diversos tipos de processos;
- Ao invés de incorporar muitos padrões em uma rede neural, padrões dedicados podem ser desenvolvidos e nesse caso poderia se ter uma rede preliminar para uma triagem de problemas e diversas redes específicas para a depuração do tipo de padrão existente;
- Nessa pesquisa os erros tipo I e tipo II são descritos em termos de  $ARL_{tx}$  que é calculado em função da janela de pontos (fixa). Uma medida mais robusta deve ser pensada;
- Um sistema especialista pode ser utilizado para a definição da causa do padrão não aleatório classificado pela rede neural. Isso completaria o ciclo da metodologia em termos de automatização. A lógica difusa pode ser aqui uma potencial ferramenta a ser utilizada;
- A saída da rede neural é um valor da função de ativação e é avaliada em termos de um valor limite para definir a classificação. O desenvolvimento de alguma medida de confiabilidade, ou intervalo de confiança é desejável;
- A supressão do analista no momento da definição do modelo a ser escolhido para os resíduos, provavelmente utilizando-se de redes neurais não supervisionadas, seria um grande avanço para a metodologia, em termos de automatização. A adoção dessa medida pode não ser adequada para muitos

processos em tempo real mas com a permissão de um tempo inicial para o treinamento da rede neural *on line*, isso seria certamente superado;

- Outras redes neurais com muitos outros parâmetros podem e devem ser testadas e certamente trarão resultados superiores aos aqui apresentados.

## 7.4 Conclusões

A pesquisa, em uma conclusão geral, mostrou que um sistema híbrido com procedimentos de séries temporais e redes neurais foi capaz de satisfazer as principais necessidades de um sistema automatizado de CEP em processos em tempo real. Os resultados obtidos foram estimulantes e a metodologia mostrou um grande poder de generalização. Ela foi desenvolvida para identificar alguns tipos clássicos de padrões de CEP, mas pode ser facilmente modificada para muitos outros tipos de padrões, como exemplificados na aplicação referente ao sinal EEG. As maiores contribuições dessa pesquisa são sumarizadas a seguir:

- Uma metodologia geral para o reconhecimento de padrões de uma carta de controle de Shewhart foi inteiramente desenvolvida;
- Um procedimento para refinamento do treinamento de padrões foi desenvolvido para uma melhor seleção do conjunto de treinamento. Com o uso desse procedimento a rede neural teve uma maior chance de finalizar o treinamento em um curto período de tempo;
- Um algoritmo para o reconhecimento de padrões envolvendo a rede neural RBF foi proposto;
- Uma inteira aplicação da metodologia foi desenvolvida, usando o sinal EEG como série temporal, abrindo uma gama de possibilidades para aplicações em tempo real;
- Várias medidas de performance foram avaliadas, considerando o RL;
- A validação da metodologia proposta e da análise de desempenho foram conduzidas considerando os erros tipo I e tipo II;

- Experimentos e resultados com outras redes neurais foram investigados. Foram comparados a performance de algumas redes neurais na tarefa de classificação dos padrões de CEP;
- Foram comparadas a classificação dos padrões de CEP usando técnicas convencionais e redes neurais;
- Foram comparadas diversas técnicas de modelamento de séries temporais possíveis em tempo real e avaliados os resultados em relação às técnicas tradicionais;
- Foram avaliadas técnicas de pré-processamento como entrada das redes neurais;
- Foi criado um banco de dados de padrões não aleatórios de CEP para comparações e aperfeiçoamentos posteriores;
- Foi desenvolvido um programa computacional para a metodologia.

## ***Bibliografia***

- 
- ADLASSNIG, K.P. (1982). **A survey on medical diagnosis and fuzzy subsets.** In Gupta, N. M., Sanchez, E., *Approximate Reasoning in Decision Analysis*, Amsterdam;
- ALWAN, L. C., ROBERTS H. V. (1989). **Time series modeling for statistical process control in automated manufacturing.** In Keats, J. B., Hubele, N. F., *Statistical Process Control in Automated Manufacturing*, 45-65, New York, Marcel Dekker;
- ALWAN, C., L.; ROBERTS, H., V. (1995). **The Problem of Misplaced Control Limits.** *Applied Statistics*, vol.44, No 3 269-278.
- ANTONIO, P. (1995). **Practical application of artificial neural networks in neurosciences.** In *Proceedings of the SPIE-The International Society for Optical Engineering. Applications and Science of Artificial Neural Networks*, 2492, 206-217.
- BEALE, R., JACKSON, T. (1992). **Neural Computing - An Introduction.** Philadelphia, PA, IOP Publishing Ltd.
- BERHOUEX, T. M., HUNTER, W. G, PALLESEN, L. (1978). **Monitoring sewage treatment plants: Some quality control aspects.** *Journal of Quality Technology*, 10;
- BILLINGS, S. A., ZHENG, G. L. (1995). **Radial basis function network configuration using genetic algorithms.** *Neural Networks*, 8(6), 877-890.
- BISHOP, C. M. (1995). **Neural Network for Pattern Recognition.** Oxford Univ Press;
- BISESSUR, Y., NAGUIB, R. N. G- (1995). **Neural networks for the detection of buried Plant.** In *Proceedings of the IEE 4th International Conference on Artificial Neural Networks*, 393-398.
- BOX, G. E., JENKINS, G. M. (1970). **Time series analysis forecasting and control.** San Francisco, CA, Holden Day, inc;
- BOX, G., LUCENO, A., (1998). **Statistical control by monitoring and feedback adjustment.** New York, John Wiley & Sons, Inc;
- BOX, G.; KRAMER, T. (1992). **Statistical Process Monitoring and Feedback Adjustment, A Discussion.** *Technometrics*, vol.34, No 3, 251-285.
- BROOMHEAD, D. S., LOWE, D. (1988). **Multivariable functional interpolation and adaptive networks.** *Complex Systems*, 2, 321-355.
- BROWN, J. R., BERGONDY, D., ARCHER, S. J. (1991). **Comparison of neural network classifiers to quadratic classifiers for sensor fusion.** In *Proceedings of the SPIE-The International Society for Optical Engineering. Applications of Artificial Neural Networks II*, 1469, 539-543.
- BROCKWELL, PETER J. AND RICHARD A. DAVIS, (1991). **Time Series: Theory and Methods.** 2nd. ed., Springer-Verlag.
- CALCUTT, R. (1995). **The Rights and Wrongs of Control Charts.** *Applied Statistics*, vol.44, No 3 279-288.

- CARPENTER G. A; GROSSBERG S. (1995). **Fuzzy-ARTMAP: A Synthesis of Neural Networks and Fuzzy Logic for Supervised Categorization and Nonstationary Prediction.** In *Fuzzy Sets, Neural Networks, and Soft Computing*; Yager, R.R. and Zadeh, L. A.
- CHAKRABARTI, S., BINDAL, N., THEUGHARAJAN, K. (1995). **Robust radar target classification using artificial neural networks.** *IEEE Transactions on Neural Networks*, 6(3), 760-766.
- CHAMP C.W.; WOODWAL W.H. (1987). **Exact Results for Shewhart Control Charts with Supplementary Runs Rules.** *Technometrics*, vol. 29,4.
- CHAU,, Y. A., GERANIOTIS, E. (1991). **Nonparametric multi-sensor image segmentation and classification.** In *Proceedings of the IEEE Conference on Decision and Control*, 3, 2361-2362.
- CHEN, S., COWAN, C. F. N., GRANT, P. M. (1991). **Orthogonal least squares learning algorithm for radial basis function networks.** *IEEE Transactions on Neural Networks*, 2(2), 302-309.
- CHENG C.S. (1989) **Group Technology and Expert Systems Concepts Applied to Statistical Process Control in Small-Batch Manufacturing.** Tese de Doutorado, Arizona State University, Tempe, AZ. (Notas Compiladas)
- CHENG, B., TITTERINGTON, D. M. (1994). **Neural networks: A review from a statistical perspective.** *Statistical Sciences*, 9(1), 2-3 0.
- CHENG, C.S. (1997). **A neural Network Approach for the analysis of Control Chart Patterns.** *International Journal of Production Research*, vol.35, No 3, 667-697.
- CIOS, K. J., TJIA, R. E., LIU, N., LANGENDERFER, R. A. (1991). **Study of continuous ID3 and radial basis function algorithms for the recognition of glass defects.** In *Proceedings of the IEEE International Conference on Neural Networks*, 1, 49-54.
- CIOS, K. J., VARY, A., BERKE, L., KAUTZ, H. E. (1992). **Application of neural networks to prediction of advanced composite structures mechanical response and behavior.** *Computing Systems in Engineering*, 3, 539-544.
- CONTRERAS, J. (1989). **Real-time manufacturing.** In Keats, J. B., Hubele, N. F., *Statistical Process Control in Automated Manufacturing*, 45-65, New York, Marcel Dekker;
- COOK, D. F., CHIU, C. C. (1998). **Using Radial Basis Function neural networks to recognize shifts in correlated manufacturing process parameters.** *IIE Transactions*, 30, 227-234;
- CORCORAN, P., LOWERY, P. (1995). **Neural processing in an electronic odour sensing system.** In *Proceedings of the IEE 4th International Conference on Artificial Neural Networks*, 415-420.
- CYBENKO, G. (1989). **Approximation by superpositions of a sigmoidal function.** *Mathematics of Control, Signals, and Systems*, 2, 303 -14.
- DAYHOFF, J. E. (1990). **Neural Network Architectures: An Introduction.** New York, Van Nostrand Reinhold.
- DECATUR, S. E. (1989). **Application of neural networks to terrain classification.** In *Proceedings of the International Conference on Neural Networks*, 1, 1284-1288.
- DEGANI, R., BORTOLAN G. (1987) **Fuzzy numbers in Computerized Electrocardiography.** *Fuzzy sets and Systems* 24, Amsterdam;



- DOOLEY, K., KAPOOR, S., DESSOUKI, M., DEVOR, R. (1986). An integrated quality system approach to quality and productivity improvement in continuous manufacturing processes. *Journal of Engineering for Industry*, vol. 108, 4;
- DUFFY, F.H., IYER, V.G., SURWILLO, W.W. (1989). *Clinical Electroencephalography and Topographic Brain Mapping*. Springer Verlag, New York;
- FREDRICKSON, S. E., TARASSENKO, L. (1995). Text-independent speaker recognition using neural network techniques. In *Proceedings of the IEE 4th International Conference on Artificial Neural Networks*, 13 -18.
- G.STONE (1986). An analysis of the delta rule and the learning of statistical associations. In D.E. Rumelhart, J.L. McClelland, *Parallel distributed processing: Explorations in the microstructure of recognition*, Cambridge, MA: MIT press;
- GRANT, E. E., LEAVENWORTH, R. S. (1988). *Statistical Quality Control*. McGraw Hill, New York;
- GUO, Y.; DOOLEY, K. J. (1992). Identification of Change Structure in Statistical Process Control. *International Journal of Production Research*, vol. 30 7.
- HAYKIN, S. (1994). *Neural Networks: A Comprehensive Foundation*. New York: MacMillan Publishing Company.
- HO, C.; CASE, K. (1994). Economic Design of Control Charts: A Literature Review for 1981-1991. *Journal of Quality Technology*, vol.1, No 26, 39-53.
- HORNICK, K. M., STINCHCOMB, M., WHITE, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359-366.
- HOYER, R.W.; ELLIS, W.C. (1996) A Graphical Exploration of SPC I. *Quality Progress*, Maio -65-73.
- HWARNG, H. B. (1995). Multilayer perceptrons for detecting cyclic data on control charts. *Int. J. Prod. Res.*, Vol 33, 11
- HWARNG H.B.; HUBELE N.F., (1993). X-Bar Control Chart Pattern Identification Through Efficient Off-line Neural Network Training. *IIE Transactions*, vol.25, 3, May.
- HWARNG, H. B. (1992). Pattern recognition on Shewhart control charts using a neural network approach. Tese de doutorado, Arizona State University, AZ;
- Hwarng, H. B., Hubele, N. F. (1991). X-bar chart pattern recognition using neural nets. 45<sup>th</sup> Annual Quality Congress, American Society for Quality Control, Milwaukee, 884-889;
- JORDAN, J. B., CHOE, H. (1992). Comparative analysis of Statistical, Rizzy, and artificial neural pattern recognition techniques. In *Proceedings of the SPIE-The International Society for Optical Engineering. Signal Processing, Sensor Fusion, and Target Recognition*, 1699, 166-176.
- KEATS, J. B., HUBELE, N. F. (1989), *Statistical Process Control in Automated Manufacturing*. New York, Marcel Dekker;
- KEMPKA, A. A. (1994). Activating neural networks: Part 1. *AI Expert*, June, 33-37.
- KOMO, D., CHANG, C. I., KO, H. (1994). Stock market index prediction using neural networks. In *Proceedings of the SPIE-The International Society for Optical Engineering.- Applications of Artificial Neural Networks V*, 2243, 516-526.

- KONG, S. G., KOSKO, B. (1990). Comparison of fuzzy and neural trucks backer-upper control systems. In Proceedings of 1990 International Joint Conference on Neural Networks, San Diego, vol. 3, 349, IEEE, NJ;
- LEONARD J. A., KRAMER M. A. (1991). Radial basis function networks for classifying process faults. IEEE Control System Magazine, 11 (3), 31-38.
- LIAO, W. S., WU S. M., ERMER, D. S. (1982). A time series approach to quality assurance. Inspection and Quality Control in Manufacturing Systems, vol. 5;
- LIPPMAN, R. P. (1987). An introduction to computing with neural nets. IEEE ASSP Magazine, April, 4-22.
- LIPPMANN, R. P. (1989). Pattern classification using neural networks. IEEE Communications Magazine, 47-64;
- LOWE, D. (1989). Adaptive radial basis function nonlinearities, and the problem of generalisation. In Proceedings of the IEE First International Conference on Artificial Neural Networks, 171-175.
- LUCY-BOULER, T.L. (1991). Using Autocorrelations, CUSUMs and Runs Rules for Control Chart, Pattern Recognition: An Expert System Approach. Tese de Doutorado, University of Alabama, Tuscalosa, Al. (Notas Compiladas)
- LUGER, G. F.; STUBBEFIELD, W. A. (1993). Artificial Intelligence – Structures and Strategies for Complex Problem Solving. Benjamin/Cummings, California
- LURE, Y. M. F., CHIOU, Y. S. P., YEH, H. Y. M., GRODY, N. C. (1992). Hardware based neural network data fusion for classification of earth surface conditions. In Conference Record of the Twenty-Sixth Asilomar Conference on Signals, Systems, and Computers, 2, 761-5.
- MAK, M. W., ALLEN, W. G., SEXTON, G. G. (1993). Speaker identification using radial basis functions. In Proceedings of the Third International Conference on Artificial Neural Networks, 138-142.
- MALONEY, P. S. (1990). Use of probabilistic neural networks for emitter correlation. In Proceedings of the SPIE-The International Society for Optical Engineering. Applications of Artificial Neural Networks, 1294, 366-377.
- MARKHAN, I. S., RAGSDALE, C. T. (1995). Combining neural networks and statistical predictions to solve the classification problem in discriminant analysis. Decision Sciences, 26, 229-242.
- MAURER, K., DIERKS, T (1991). Atlas of Brain Mapping. Springer Verlag, Berlin;
- MILLER, R. K., WALKER, T.C. (1988). Artificial Intelligence Applications in Manufacturing. Madison, GA;
- MITTAG, H. J.; RINNE, H. (1993). Statistical methods of Quality Assurance. Chapman&Hall - Glasgow -393-44.
- MONTGOMERY, D. C. (1995). Introduction to Statistical Quality Control. New York, John Wiley & Sons;
- MONTGOMERY, D. C. FRIEDMAN, D. J. (1989). Statistical Process Control in a Computer-Integrated Manufacuting Environment. In Keats, J. B., Hubele, N. F., Statistical Process Control in Automated Manufacturing, 45-65, New York, Marcel Dekker;

- MOODY, J., DARKEN, C. J. (1989). **Fast learning in networks of locally-tuned processing units.** *Neural Computation*, 1, 281-294.
- MORENO, L., PINEIRO, J. D., SANCHEZ, J. L., MANAS, S., MERINO, J. J., ACOSTA, L., HAMILTON, A. (1995). **Using neural networks to improve classification: Application. to brain maturation.** *Neural Networks*, 8(5), 815-820.
- MUSAVI, M. T., AHMED, W., CHAN, K. H., FARIS, K. B., HUMMELS, D. M. (1992). **On the training of radial basis function classifiers.** *Neural Networks*, 5(4), 595-603.
- NEKOVEI, R., SUN, Y. (1995). **Back-propagation network and its configuration for blood vessel detection in angiograms.** *IEEE Transactions on Neural Networks*, 6(1), 64-71.
- NELSON L.S.(1985). **Interpreting Shewhart X-bar Control Charts.** *Journal of Quality Technology*, vol. 17,2.
- NELSON, M., ILLINGWORTH, W. (1990). **A Practical Guide to Neural Nets.** New York: Addison-Wesley Publishing Company.
- NOTOHARDJONO, B. D., ERMER, D. S. (1986). **Time series control charts for correlated and contaminated data.** *Journal of Engineering for Industry*, 108, 226;
- PAO, Y. H.(1989). **Adaptive pattern recognition an neural Networks.** Reading, Ma, Addison-Wesley;
- PARK J., SANDBERG I. W. (1991). **Universal approximation using radial basis function networks.** *Neural Computation*, 3, 246-257.
- PHAM, D. T., OZTEMEL, E. (1992). **A knowledge-based statistical process control system.** Second International Conference on Automation, Robotics and Computer Vision, Singapore, 3, 16-18;
- PHAM, D. T., OZTEMEL, E. (1992). **Control chart pattern recognition using neural networks.** *Journal of Systems Engineering*, 2, 4, Special Issue on Neural Networks, 256-262;
- RAWLINGS, J. O. (1988). **Applied regression analysis: a research tool.** Pacific Grove, CA; Wadsworth & Brooks/Cole advanced Books & Software;
- REFENES, A. N., ZAPRANIS, A., FRANCIS, G. (1994). **Stock performance modeling using neural networks: A comparative study with regression models.** *Neural Networks*, 7(2),375-388.
- RENALS, S., ROHWER, R. (1989). **Phoneme classification experiments using radial basis functions.** In *Proceedings of the 1989 International Joint Conference on Neural Networks*, 1, 461-467.
- RIPLEY, B. D. (1994). **Neural networks and related methods for classification.** *Journal Royale Statistical Society*, 56(3), 409-456.
- ROGERS, S. K., RUCK, D. W., KABRISKY, M., TARR, G. L. (1990). **Artificial neural networks for automatic target recognition.** In *Proceedings of the SPIE-The International Society for Optical Engineering.- Applications of Artificial Neural Networks*, 1294, 2-12.
- RUMELHART, D.E., HINTON, G. E., WILLIAMS, R. J. (1986). **Learning internal representations by error propagation.** In D.E. Rumelhart, J.L. McClelland , *Parallel distibuted processing: Explorations in the microstructure of recognition*, Cambridge, MA: MIT press;
- RUSSEL S., NORVIK, P.(1995). **Artificial Intelligence – A Modern Approach.** Prentice Hall New Jersey.

- SAHRMANN, H. (1979). Set-up assurance through time series analysis. *Journal of Quality Technology*, 11, 105-115.
- SAMOHYL, R. W., BALESTRASSI, P. P., MEURER, R. (1998). *Inteligência Artificial Aplicada ao Controle Estatístico de Processos em Sistemas Automatizados de Manufatura*. XVIII Congresso Brasileiro de Engenharia de Produção e IV Congresso Internacional de Engenharia Industrial" 06 a 09 Out/98 Niterói/RJ.
- SAMOHYL, R. W., BALESTRASSI, P. P., MEURER, R. (1998) *Métodos de Previsão usando a série econométrica de Nelson-Plosser: Um estudo comparativo*. XVIII Congresso Brasileiro de Engenharia de Produção e IV Congresso Internacional de Engenharia Industrial" 06 a 09 Out/98 Niterói/RJ.
- SCHALKOFF, R.J. (1990). *Artificial Intelligence – an Engineering Approach*. McGraw-Hill, New York.
- SERPICO, S. B., ROLI, F., PELLEGRETTI, P., VEMAZZA, G. (1993). *Structured neural networks for the classification of multisensor remote-sensing images*. In *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*, 2, 907-909.
- SHERSTINSKY, A., PICARD, R. W. (1996). *On the efficiency of the orthogonal least squares training method for radial basis function networks*. *IEEE Transactions on Neural Networks*, 7(1), 195-200.
- SMITH, A. E. (1994). *X-bar and R control chart interpretation using neural computing*. *International Journal of Production Research*, vol.32, No 2, 309-320;
- SMOTROFF, L. G., HOWELLS, T. P., LEHAR, S. (1990). *Meteorological classification of satellite imagery using neural network data fusion*. In *Proceedings of the International Joint Conference on Neural Networks*, 2, 23 -28.
- SPURRIER, J. D., THOMBS, L. A. (1990). *Control charts for detecting cyclical behavior*. *Technometrics*, 32(2), 163-171;
- SWIFT, J.A. (1987). *Development of a Knowledge-Based Expert System for Control Chart Pattern Recognition and Analysis*. Tese de Doutorado, Oklahoma State University. (Notas Compiladas)
- TANG, Y., WEE, W. G., HAN, C. Y. (1991). *Application of a multilayer network in image object classification*. In *Proceedings of the SPIE-The International Society for Optical Engineering.- Applications of Artificial Neural Networks II*, 1469, 113-119.
- TARN, K. Y., & KIANG, M. Y. (1992). *Managerial applications of neural networks: The case of bank failure predictions*. *Management Science*, 38(7), 926-947.
- TONTINI G. (1995). *Automatização da Identificação de Padrões em Gráficos de Controle Estatístico de Processos (CEP) Através de Redes Neurais com Lógica Difusa*. Tese de Doutorado UFSC.
- WESTERN ELECTRIC CO. INC.(1958). *Statistical Quality Control Handbook*. New York. (Excertos In Mittag/Rinne, 1993)

- WHITTINGTON, G., SPRACKLEN, T. (1990). **Application of a neural network model to sensor data fusion.** In Proceedings of the SPIE-The International Society for Optical Engineering. Applications of Artificial Neural Networks, 1294, 276-283.
- WHITTINGTON, G., SPRACKLEN, T., HAUGH, J., FAULKNER, H. (1993). **Automated radar behaviour analysis using neural network architectures.** In Proceedings of the SPIE-The International Society for Optical Engineering. Science of Artificial Neural Networks II, 1966, 44-59.
- WIDROW, B. HOFF, M. E. (1960). **Adaptive switching circuit.**, 1960 WESCON Convention, Record Part IV 96-104;
- WONG, Y. (1991). **How Gaussian radial basis functions work.** In Proceedings of the IEEE International Conference on Neural Networks, 2, 13 3 -13 8.
- YEGNANARAYANA, B., CHOUHAN, H. M., SEKHAR, C. C. (1992). **Sonar target recognition using radial basis function networks.** In Proceedings of the ICCS/ISITA 1992: Communications on the Move, 395-399.
- ZAHEDI, F. (1991). **An introduction to neural networks and a comparison with artificial intelligence and expert systems.** Interfaces, 21, 25-38.
- ZURADA, J. M. (1992). **Introduction to Artificial Neural Systems.** New York: West Publishing Company.

## Anexo A – Geração de Padrões

---

### Equação geral para a geração de padrões:

$$y(t) = \mu + x(t) + d(t)$$

com  $y(t)$ : Série temporal no tempo  $t$ ;

$\mu$ : Média do processo ( $=0$ );

$x(t)$ : Variável aleatória normal  $N(0, \Gamma\sigma)$ ;

$\sigma$ : Desvio padrão do processo ( $=1$ );

$\Gamma$ : Amplitude do ruído em termos de  $\sigma$ , ( $0 < \Gamma < 1$ );

$d(t)$ : Padrão não aleatório no tempo  $t$ ;

$t_0$ : Um ponto de referência;

### Padrão Natural:

$$y(t) = \mu + x(t)$$

com  $\Gamma = 1$ ;

### Tendência:

$$d(t) = (t - t_0) \alpha \sigma$$

com  $\alpha$ : Inclinação da tendência;

### Ciclo:

$$d(t) = \sin[2\pi(t - t_0)/\Omega] k \sigma$$

com  $k$ : Amplitude do ciclo;

$\Omega$ : Período do ciclo;

### Padrão Sistemático:

$$d(t) = (-1)^t \Phi \sigma$$

com  $\Phi$ : Amplitude do padrão sistemático. Tal parâmetro determina a flutuação acima e abaixo da média do processo.  $\Phi > 0$ ;

**Estratificação:**

$$y(t) = \mu + x(t) + d$$

com  $x(t)$ : Variável aleatória  $N(0, \Gamma\sigma)$  e  $0 < \Gamma < 0.2$ ;

$d$ : *Offset* da média do processo. O centro da estratificação com  $0 < d < 0.2$ ;

**Mistura:**

$$d(t, p) = (-1)^w m \sigma$$

com  $p$ : Um número aleatório entre 0 e 1;

$m$ : Amplitude da mistura em termos de  $\sigma$ ,  $m > 0$ ;

$w=0$  se  $p < mp$ ,  $w=1$  se  $p > mp$ ;

$mp$ : Valor de probabilidade que determina o deslocamento entre distribuições;

**Desvio da Média:**

$$d(t, t_s) = (-1)^s u \sigma$$

com  $t_s$ : Ponto onde o deslocamento ocorre;

$s=0$  se  $t \geq t_s$  e o deslocamento é crescente;  $s=1$  se  $t < t_s$  e o deslocamento é decrescente;

$u$ : Amplitude do deslocamento do processo em termos de  $\sigma$ ,  $u=0$  se  $t < t_s$ .

## Anexo B – Mínimos Quadrados Ortogonais

### Localização dos Centros Usando Mínimos Quadrados Ortogonais

Esse Apêndice descreve o método de Mínimos Quadrados Ortogonais (*Orthogonal Least Squares* – OLS) usados por Chen, Cowan, and Grant (1991) (CCG) para localizar os centros em uma RBFN. O desenvolvimento aqui apresentado foi extraído do artigo desses autores.

Primeiro, considere a RBFN como um caso especial de um modelo de regressão linear:

$$d(t) = \sum_{i=1}^k p_i(t)\gamma_i + \varepsilon(t) \quad (\text{B.1})$$

onde  $d(t)$  representa a variável dependente (ou saída desejada),  $\gamma_i$  são os parâmetros e  $p_i(t) = p_i(x(t))$ .  $\varepsilon(t)$  são os termos regressores assumidos como não correlacionados. Um centro fixo  $\theta_i$  com uma dada não linearidade  $\phi(\bullet)$  corresponde ao termo regressor  $p_i(t)$  na equação B.1 acima.

CCG reescrevem a equação B.1 em termos matriciais para  $t=1$  até  $N$ . Isto é:

$$d = P\Gamma + E \quad (\text{B.2})$$

onde

$$d = [d(1) \dots d(N)]^T, P = [p_1 \dots p_k], p_i = [p_i(1) \dots p_i(N)]^T, \dots, 1 \leq i \leq k, \Gamma = [\gamma_1 \dots \gamma_k]^T, E = [\varepsilon(1) \dots \varepsilon(N)]^T$$

Os vetores regressores  $p_i$  formam um conjunto de vetores de bases e a solução de mínimos quadrados  $\hat{\Gamma}$  satisfaz a condição de que  $P\hat{\Gamma}$  seja a projeção de  $d$  no espaço definido por esses vetores. CCG definem o quadrado da projeção  $P\hat{\Gamma}$  como uma parteda “energia” de saída desejada que é explicada pelos regressores.

CCG defende que, desde que o método OLS transforma o conjunto  $p_i$  em um conjunto de bases ortogonais, é possível calcular a contribuição individual para a energia de saída desejada a partir de cada vetor da base. Isto é, o poder explanatório individual de cada centro pode ser determinado.

A matriz de regressão  $P$  pode ser decomposta em:

$$P = WA \quad (\text{B.3})$$



onde  $A$  é uma matriz triangular  $k$  por  $k$  com valores unitários na diagonal, valores zeros abaixo da diagonal, e entradas diferentes de zero  $\alpha_{jk}$  acima da diagonal; e,  $W$  é uma matriz  $N$  por  $k$  com colunas ortogonais  $w_i$  tal que:

$$W^T W = H \quad (\text{B.4})$$

onde  $H$  é a diagonal com elementos  $h_i$ :

$$h_i = w_i^T w_i = \sum_{t=1}^N w_{it}^2, \dots 1 \leq i \leq k \quad (\text{B.5})$$

O espaço abrangido pelo conjunto de vetores ortogonais  $w_i$  é o mesmo espaço abrangido pelo conjunto de  $p_i$ , e a equação B.2 pode ser reescrita como:

$$d = Wg + E \quad (\text{B.6})$$

A solução do OLS é dada por:

$$\hat{g} = H^{-1} W^T d \quad (\text{B.7})$$

ou

$$\hat{g}_i = \frac{W_{it}^T d}{W_{it}^T w_i} \dots 1 \leq i \leq k \quad (\text{B.8})$$

A quantidade  $\hat{g}$  e  $\hat{\Gamma}$  satisfazem a igualdade:

$$A\hat{\Gamma} = \hat{g} \quad (\text{B.9})$$

CCG usam o método clássico de Gram-Schmidt para ortogonalizar  $P$  como segue:

$$w_1 = p_1 \quad (\text{B.10})$$

$$\alpha_{il} = \frac{W_{it}^T p_l}{W_{it}^T w_i} \dots 1 \leq i \leq l \quad (\text{B.11})$$

$$w_l = p_l - \sum_{i=1}^{l-1} \alpha_{il} w_i \quad (\text{B.12})$$

Esse processo é reiterado para  $i=2$  até  $k$ .

Devido a  $w_i$  e  $w_j$  serem ortogonais para  $j \neq i$ , o quadrado da soma de  $d(t)$  é dado por:

$$d^T d = \sum_{i=1}^k g_i^2 w_i^T w_i + E^T E \quad (\text{B.13})$$

CCG notaram que se  $d$  é o vetor de saída desejado após sua média ser removido, então a variância de  $d(t)$  é dada por:

$$N^{-1} d^T d = N^{-1} \sum_{i=1}^k g_i^2 w_i^T w_i + N^{-1} E^T E \quad (\text{B. 14})$$

$N^{-1} \sum_{i=1}^k g_i^2 w_i^T w_i$  é a parte da variância de saída desejada que pode ser explicada pelos termos regressores e  $N^{-1} g_i^2 w_i^T w_i$  é o incremento da variância de saída o qual é explicada por  $w_i$ . CCG definem uma taxa de redução de erro para  $w_i$  como:

$$(err)_i = \frac{g_i^2 w_i^T w_i}{d^T d}, \dots, 1 \leq i \leq k \quad (\text{B.15})$$

Os autores usam tal razão para selecionar um subconjunto de regressores significantes, como segue. Primeiro são computadas as equações:

$$\begin{aligned} w_1^{(i)} &= p_i \\ g_1^{(i)} &= \frac{(w_1^{(i)})^T d}{(w_1^{(i)})^T w_1^{(i)}} \\ (err)_1^{(i)} &= \frac{(g_1^{(i)})^2 (w_1^{(i)})^T w_1^{(i)}}{d^T d} \end{aligned} \quad (\text{B.16})$$

Depois encontra-se:  $(err)_1^{(il)} = \max\{(err)_i^{(i)}, 1 \leq i \leq M\}$  e seleciona-se  $w_1 = w_1^{(il)} = p_{i_1}$ .

No passo  $l$ , onde  $l \leq 2$ , para  $1 \leq i \leq M, i \neq i_1, \dots, i \neq i_{l-1}$  computa-se:

$$\begin{aligned} \alpha_{jl}^{(i)} &= \frac{w_j^T p_i}{w_j^T w_j} \dots 1 \leq j \leq l \\ w_l^{(i)} &= p_i - \sum_{j=1}^{l-1} \alpha_{jl}^{(i)} w_j \dots 1 \leq j \leq l \\ g_l^{(i)} &= \frac{(w_l^{(i)})^T d}{(w_l^{(i)})^T w_l^{(i)}} \end{aligned}$$

$$(err)_i^l = \frac{(g_i^{(i)})^2 (w_i^{(i)})^T w_i^{(i)}}{d^T d} \quad (\text{B.17})$$

encontra-se  $(err)_i^{(il)} = \max\{(err)_i^{(i)}, 1 \leq i \leq M, i \neq i_1, \dots, i \neq i_{l-1}\}$  e seleciona-se

$w_l = w_l^{(il)} = p_{il} - \sum_{j=1}^{l-1} \alpha_{jl} w_j$  onde  $\alpha_{jl} = \alpha_{jl}^{(il)}, 1 \leq j \leq l$ . O procedimento é concluído no

passo  $k$  quando  $1 - \sum_{j=1}^k (err)_j < \rho$  onde  $\rho$  é uma tolerância conhecida.

## **Anexo C – Código Computacional**

Foi considerada desnecessária a publicação de todo o código computacional em MatLab, uma vez que ele pode ser obtido pelo e-mail [pedro@iem.efei.br](mailto:pedro@iem.efei.br). A seguir serão apresentadas apenas as descrições dos procedimentos desenvolvidos. Esse programa foi desenvolvido experimentalmente em MatLab 5.0 e uma versão profissional em Visual C vem sendo testada como uma subrotina a ser inserida nos equipamentos da empresa Neurotec. Tem-se em vista a sua distribuição em caráter nacional para teste e avaliação da metodologia.

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% Pedro Paulo Balestrassi UFSC/EPS 2000
%
%      As seguintes principais rotinas foram desenvolvidas para a
% simulacao da metodologia em um sistema de manufatura automatizado
% considerando o reconhecimento de padroes de CEP em tempo real:
%
% - Rotina Principal (MAIN.M)
% - Aquisicao dos dados pelo programa (DATA_SET.M)
% - Define Estado do Processo (SETUP.M)
% - Cálculo dos Resíduos (RESIDUAL.M)
% - Classificacao de Padroes (PATTERN.M)
% - Apresentacao dos Resultados e Estatisticas (RESULTS.M)
%
%      Outras rotinas foram desenvolvidas com o objetivo de realizar
% procedimentos complementares, nao fazendo parte do programa
% final. Sao elas:
%
% - Metodos de estimacao e calculo de residuos de series temporais
%   em tempo real (ESTIMATION.M)
% - Geracao dos padrões de CEP (DATA CEP.M)
% - Treinamento da Rede RBF (RBF_TRAINING.M)
% - Teste da Rede RBF (RBF_TEST.M)
% - Tratamento do problema da invariancia (CICLOS.M)
% - Aplicacao: Video EEG (VIDEOEEG.M)
%
```

### **Rotina Principal (MAIN.M)**

```

%      Tal rotina e composta das cinco principais subrotinas citadas
% anteriormente, segundo uma linguagem estruturada:
%
%      DATA_SET.M, SETUP.M, RESIDUAL.M, PATTERN.M, RESULTS.M
%
%      O calculo dos residuos deve ser executado apos a aquisicao de
% amostras (por meio de um conversor analogico digital em aplicacoes
% tempo real) e a serie de residuos sera submetida a rede neural
% treinada off-line para a verificacao de anormalidades em um
% processo.
%
%      O programa avalia os resultados da rede neural treinada off-line
% para os seguintes padroes de CEP.
%
%      Tendencias          Ciclos          Estratificação
%      Sistemáticos        Mistura         Deslocamentos
%
% Algoritmo estruturado basico:
%      BEGIN
```

```

% Define Estado do Processo (SETUP.M)
% REPEAT
%     Define conjunto de dados (DATA_SET.M)
%     Calculo dos Residuos (RESIDUAL.M)
%     Classifica os Padroes (PATTERN.M)
%     Mostra Resultados (RESULTS.M)
% END
% END
%

```

#### Rotina de Aquisicao dos dados pelo programa (DATA\_SET.M)

```

% Os dados externos podem ser obtidos de duas formas basicas:
% 1) Pela leitura de um arquivo de dados no formato .txt gerados
%    pelo usuario. (aqui utilizado)
% 2) Pela leitura de um arquivo de dados usando resultados de um
%    Conversor Analogico Digital.
%
% Algoritmo basico:
% Variaveis:
% p=posicao da primeira amostra
% N=numero de amostras
% BEGIN
%   Le N amostras a partir de p
%   incrementa p
% END
%
% O mecanismo de deslizamento da janela de pontos e utilizado para
% que haja sempre as n ultimas amostras da serie temporal.

```

#### Define Estado do Processo (SETUP.m)

```

% O usuario e levado a definir se o processo esta sob controle e a
% escolher um modelo da serie temporal do processo. Algumas variaves
% sao aqui definidas:
% N:          numero de amostras
% *.txt:      Nome do arquivo de Dados
% Model       Modelo selecionado
%
% Algoritmo basico:
% BEGIN
%   IF Processo esta sob controle
%     Abre o arquivo de dados
%     Seleciona Modelo (MODEL.M)
%   ENDIF
% END
%
% MODEL.M
% BEGIN
%   REPEAT
%     Mostra lista de Modelos
%     IF Modelo Compativel com Processo THAN Seleciona Model END
%     IF Novo Processo THAN Novo Modelo (ESTIM.M); Grava Modelo; END
%   UNTIL Model Selecionado
% END
%
% ESTIM.M
% BEGIN
%   Calcula a ordem do parametro autoregressivo (ARORDER.M)

```

```
%      Calcula a ordem do parametro de medias moveis(MAORDER.M)
%      Estima os parametros (ARMARTS.M)
%      Grava o modelo na Lista de mdelos
%      END
%      (ver adiante em ESTIMATION.M)
%      ARORDER      Estima a ordem do modelo AR
%      MAORDER      Estima a ordem do modelo MA
%      ARMARTS      Estima os parametros ARMA pelo metodo dos residuos
```

#### Calculo dos Residuos da Serie de dados (RESIDUAL.M)

```
%      Obtido o modelo da serie temporal, o calculo do conjunto de
%      residuos pode ser facilmente calculado uma vez que tais residuos
%      consistem na diferenca entre os valores observados e os valores
%      previstos pelo modelo.
%      Variaveis
%      Amost : Numero N de amostras da serie
%      Estim : Numero N de valores estimados da serie
%      Model : Modelo da serie
%      Resid : Conjunto de residuos da serie
%
%      Algoritmo basico:
%      BEGIN
%      Le Amost
%      Calcula Estim com Model
%      Resid=Amost-Estim
%      END
```

#### Classificacao de Padroes (PATTERN.M)

```
%      Classifica os padroes exibidos nos residuos de acordo com os mais
%      comuns padroes de CEP. Tal programa faz uso da Rede Neural de Funcao
%      de Base Radial.
%      Variaveis
%      Resid : Conjunto de residuos da serie
%      pattern: Padrao da carta de residuos (resposta da Rede Neural)
%
%      Algoritmo basico:
%      BEGIN
%      Le Resid
%      Le os pesos da rede neural treinada Off-line
%      Classifica os residuos (RBF_TES.M)
%      END
%
%      pattern=RBF_TES(P,W1,B1,W2,B2)
%      P - Cartas de controle dos residuos (Resid)
%      W1 - S1xR matriz de pesos para a camada de base radial.
%      B1 - S1x1 vetor de bias para a camada de base radial.
%      W2 - S2xS1 matriz de pesos da camada linear.
%      B2 - S2x1 vetor de bias para a camada linear.
%      Retorna a saida da rede.
```

#### Mostra Resultados (RESULTS.M)

```
%      Os resultados de classificacao sao apresentados segundo um
```

```

% intervalo de tempo para averiguacao do usuario quanto ao resultado
% do processo. Em tempo real pode-se ativar mecanismos de alerta
% sempre que um numero de padroes fora de controle for atingido.
% Variaveis
%   pattern: Resultados da classificacao
%   T: Perodo de atualizacao de histogramas
%   Alarm: Numero de padroes de ocorrencia em sequencia para alarme
%   Results: matriz PxQ com P=padrao (0..6) e Q=numero de
%           ocorrencias
%
% Algoritmo basico:
%   BEGIN
%       Le Pattern
%       Atualiza Histograma de Results a cada T classificacoes
%       Envia alerta a cada Alarme
%   END
%

```

#### Metodos de estimacao e Calculo de Residuos de Series Temporais em tempo real (ESTIMATION.M)

```

%   A seguir estao listados os procedimentos utilizadas nesse
%   programa que culminaram com a definicao de alguns metodos de
%   estimacao de modelos autoregressivos de series temporais.
%
%   acovf           Funcao de autocovariancia
%   acorf (acf)     Funcao de autocorrelacao
%   pacf           Funcao de autocorrelacao parcial
%   acf2pacf       Converte acf em pacf
%   biacovf        Funcao de bi-autocovariancia (cumulante de terceira
%                   ordem)
%   yuwa           Resolve a equacao de Yule-Walker - converte ACOVF em
%                   parametros AR
%   invest0        Uma investigacao a priori(usada por invest1)
%   invest1        Investigacao da serie de dados(usada na comparacao
%                   de series classicas)
%   selmo          Seleciona a ordem do modelo autoregressivo usando
%                   diferentes criterios.
%   ARORDER        Estima a ordem do modelo Autoregressivo
%   MAORDER        Estima a ordem do modelo de medias moveis
%   eigval         Calcula os autovalores da matriz de autocovariancia
%
%   Estimacao do modelo Autoregressivo
%   ARRCES        Metodo baseado em cumulantes.
%   MAEST         Algoritmo GM-RCLS
%   ARMAQS        Algoritmo q-slice
%   ARMARTS       Metodo de residuos de series temporais
%   earpyw        Yule-Walker (com o algoritmo de Levinson-Durban)
%   earpk         Metodo usando filtragem de Kalman
%   earplms       Metodo LMS
%
%   Programas uteis
%   Demo          Demonstra as rotinas de Estimacao
%
%   sim2          Programa Gerador de Ruidos
%
%   tsademo2      Demonstra deteccao de Picos (Spikes) em sinais com
%                   ruidos
%

```

```

%
%      demoperf      Demonstra o aumento de performance de EARPYW.M
%                    comparado com AR.M
%
%      Series_test   Comparacao dos metodos de estimacao com series
%                    temporais classicas
%      sinvest1      Mostra parametros calculados por INVEST1
%      tsademo       Demonstra INVEST1 para dados EEG
%      WACF          Funcao de autocorrelacao ponderada
%      ARPMx         Matriz de parametros autoregressivos
%      E             Funcao erro E(p)
%
% Descricoes:
%
%      acovf Funcao de Autocovariancia
%
%      [ACF,WACF] = acovf(Z,KMAX);
%
%      Descricao
%      [ACF,WACF] = acovf(Z,N);
%      Entrada:  Z      Sinal
%               N+1    # de coeficientes
%      Saida:    ACF    Funcao de Autocorrelacao
%               WACF    Funcao de Autocorrelacao Ponderada
%      Funcao chamada por acorf e earpyw
%
%      acorf (acf) Funcao de Autocorrelacao
%
%      [ACF] = acorf(Z,N);
%
%      Descricao
%      Funcao de Autocorrelacao (fast)
%      [ACF] = acorf(Z,N);
%      Entrada:  Z      Sinal
%               N      # de coeficientes
%      Saida:    ACF    Funcao de Autocorrelacao
%
%      Funcao chamada por pacf. Chama acovf
%
%      acf2pacf converte Funcao de Autocorrelacao para ACF Parcial
%
%      [PACF,PHI,PE]= acf2pacf(ACF,E0);
%
%      Descricao
%      [PACF] = acf2pacf(ACF);
%      converte ACF em PACF
%
%      Funcao chamada por pacf
%
%      biacovf bi-funcao de Autocovariancia (cumulante de 3rd ordem)
%
%      [BIACF,ACF,M1] = biacovf(Z,N);
%
%      Descricao
%      Bi-Funcao de Autocovariancia
%      [BiACF] = biacovf(Z,N);

```



```

%      Entrada:  Z      Sinal
%               N      # de coeficientes
%      Saida:   BIACF bi-Funcao de Autocorrelacao
%               ACF funcao de covariancia
%
% pacf Funcao de Autocorrelacao Parcial
%
%      [PACF]= pacf(Z,KMAX);
%
%      Descricao
%      Funcao de Autocorrelacao Parcial
%      [PACF] = pacf(Z,N);
%      Entrada:  Z      Sinal
%               N      # de coeficientes
%      Saida:    PACF Funcao de Autocorrelacao Parcial
%
%      Chama acf2pacf e acorf
%
% yuwa Resolve a equacao de Yule-Walker (converte ACOVF em
% parametros AR
%
%      [arp] = yuwa(ACF);
%
%      Descricao
%      funcao [arp] = yuwa(ACF);
%      estima o parametro do modelo AR(p) resolvendo a equacao de
%      Yule-Walker
%      ACF Funcao de Autocovariancia [0..P]
%      arp Parametro do modelo autoregressivo
%
%      Funcao chamada por earpyw
%
% invest0 Uma investigacao a priori (usada por invest1)
%
%      [ACOVF,ACF,PACF,ARPMx,E,PE]=invest0(Y,Pmax);
%
%      Descricao
%      [ACOVF,ACF,PACF,ARPMx,E]=invest0(Y,Pmax);
%      Y      Serie Temporal
%      Pmax   Maxima ordem (opcional)
%      ACOVF  Autocovariancia
%      ACF    Autocorrelacao
%      PACF   Autocorrelacao Parcial
%      ARPMx  Matriz de Parametros Autoregressivos
%             ARPMx(p,1:p) fornece os parametros para o modelo de
%             ordem p
%      E      Funcao Erro E(p)
%
%      Funcao chamada por invest1
%
% invest1 investiga o sinal (usada para a avaliacao inicial dos
% dados)
%
%      Descricao
%      [ACOVF,ACF,PACF,ARPMx,E,CRITERIA,MOPS]=invest1(Y,Pmax,show);
%
%      show   opcional (Se existentes, os parametros sao mostrados

```

```

% Demais itens (idem anterior)
%
%
% CRITERIA
% FPE Final Prediction Error (Kay, 1987)
% AIC Akaike Information Criterion (Marple, 1987)
% BIC Bayesian Akaike Information Criterion (Wei, 1994)
% SBC Schwartz's Bayesian Criterion (Wei, 1994)
% MDL Minimal Description length Criterion (Marple, 1987)
% CAT Parzen's CAT Criterion (Wei, 1994)
% PHI Phi criterion (Pukkila et al. 1988)
% mine      ordem onde E e minimo
%
% MOPS
% optFPE      ordem onde FPE e minimo
% optAIC      ordem onde AIC e minimo
% optBIC      ordem onde BIC e minimo
% optSBC      ordem onde SBC e minimo
% optMDL      ordem onde MDL e minimo
% optCAT      ordem onde CAT e minimo
% optPHI      ordem onde PHI e minimo
%
% Funcao chamada por Demo e tsademo2. Chama invest0,selmo, sinvest1
%
%      selmo Seleciona a ordem do modelo Autoregressivo usando varios
%      criterios
%
%      [FPE,AIC,BIC,SBC,MDL,CAT,PHI,optFPE,optAIC,optBIC,optSBC,
%      optMDL,optCAT,optPHI]= selmo(E,N);
%
% Descricao
%
% E      funcao Erro E(p)
% N      Ordem Maxima (opcional)
% Demais itens (idem anterior)
%
% Funcao chamada por invest1
%
% ARORDER Estima a ordem do modelo AR
%
% p=arorder (y, norder, pmax, qmax, flag)
%
% Descricao
% y      - Serie temporal
% norder - Ordem do cumulante (2,3,4,-3 ou -4) [def= 3]. Um valor
%         de -3 ou -4 indica que ambos, correlacao e cumulantes
%         de terceira (ou quarta) ordem devem ser usados
% pmax   - Ordem maxima do modelo AR [def=10]
% qmax   - Ordem maxima do modelo MA [def=10]
% flag   - Igual a 1 se o valor de "p" e internamente escolhido
%         (forma automatica). De outra forma os valores
%         singulares sao mostrados e o usuario e levado a
%         escolher a ordem estimada do modelo.
% p      - Ordem estimada do modelo AR
%
% MAORDER MA order determination
%
% gopt = maorder(x, qmin, qmax,pfa, flag)

```

```

% Descricao
% x - series temporais (Deve ser um vetor)
% qmin - Ordem minima para MA [default = 0]
% qmax - Ordem Maxima para MA [default = 10]
% pfa - Probabilidade de falso alarme [default = 0.05]
% flag - Se diferente de zero (default = 1), varios valores sao
% apresentados
% qopt - Ordem estimada de MA
%
% ARMATS Estimacao dos parametros ARMA pelo metodo de
% Residuos de Series temporais
% [avec, bvec] = armats(y,p,q,order,maxlag,samp_seg,overlap,flag)
% y : Serie Temporal (vetor ou matriz)
% p : ordem AR
% q : ordem MA
% norder: Ordem do cumulante: -4, -3, 3 ou 4 [default = 3 ]
% -3 : Usar correlacao e cumulante de terceira ordem
% -4 : Usar correlacao e cumulante de quarta ordem
% maxlag: Maximo lag do cumulante a ser usado [default = p+q]
% samp_seg: amostras por segmento para estimacao dos cumulantes
% [default = numero de amostras de y]
% overlap : percentagem de segmentos sobrepostos [default = 0]
% flag : 'biased' or 'unbiased' [default = 'biased']
% avec : Vetor de parametros AR estimados
% bvec : Vetor de parametros MA estimados
%
% ARRCEST Estimacao dos parametros AR baseados em cumulantes
%
% avec = arrcest (y,p,q, norder,maxlag,samp_seg,overlap,flag)
%
% Descricao
% (idem ARMATS)
%
% MAEST Estimacao dos parametros MA pelo algoritmo GM-RCLS
%
% bvec = maest (y, q, norder, samp_seg, overlap, flag)
%
% Descricao
% (idem ARMATS)
%
% ARMAQS Estimacao dos parametros ARMA pelo algoritmo q-slice
%
% [avec, bvec] = armaqs(y,p,q,norder,maxlag,samp_seg,overlap,flag)
%
% Descricao
% (idem ARMATS)
%
% eigval Calc. Autovalores da Matriz de Autocovariancia
%
% histo Histograma
%
% [H,X]=histo(Y,N)
% Plota o histograms de barras [bar(X,H)]
% Funcao chamada por Demo
%
% earpyw Yule-Walker (com o algoritmo de Levinson-Durban)

```

```

%
% [ARP, se, sy] = earpyw(Y,p);
%
%
% Descricao
% funcao[ARP, se, sy] = earpyw(Y,p);
%     Estima os parametros do modelo AR resolvendo a equacao de
%     Yule-Walker para a ordem p
%     EARPYW(Y,p) e o mesmo que AR(Y,p,'yw') porem muito mais rapido;
%
%     Y    Serie Temporal
%     p    Ordem do modelo
%     ARP  Parametros estimados do modelo
%     sy   Variancia estimada = acf(0)
%     se   Variancia estimada do erro do processo(ruido branco)
%
% Chama acovf, yuwa
%
% earpk - Estimacao pelo metodo de filtragem de Kalman
%
% [a,A] = earpk(Y,p);
%
% Descricao
% [a,A] = earpk(Y,p);
%     Estima parametros do modelo AR
%      $Y(t) = a' * Y(t-1) + E(t)$ 
%     usando uma aproximacao pelo filtro de Kalman
% Entrada:
%     p    ordem do modelo
%     Y    Sinal (Processo AR)
% Saida:
%     a    Parametro AR
%     A    Matriz de Varincia/Covariancia
%
% earplms    Metodo LMS
%
% [a] = earplms(Y, p, UC);
%
% Descricao
% [a] = earplms(Y, p, UC);
%     Estima os Coeficientes do processo AR
%      $Y(t) - a * Y(t-1) = E(t)$ 
%     usando o metodo (LMS)Least Mean Square
% Entrada: Y    Sinal
%     p    ordem do modelo
%     UC    parametro incremental (default= 0.01/var{Y})
% Saida:
%     a    Parametros AR
%
% sinvest1    Mostra os parametros calculados por INVEST1
%
% sim2        Gerador de Ruidos
%
% Demo        Demonstra as rotinas de Estimacao
%
% tsademo     Demonstra INVEST1 para dados EEG
%
% tsademo2    Demonstra deteccao de Picos (Spikes) em sinais com
%              ruidos

```

```
%
%      demoperf      Demonstra o aumento de performance de EARPYW.M
%                    comparado com AR.M
%
%      Series_test   Comparacao dos metodos de estimacao com series
%                    temporais classicas
%      Foram testadas as seguintes series:
%      - Serie de temperaturas descrita em Box/Luceño (1998)
%      - Serie de filmes metálicos (Box/Luceño-1998)
%      - Serie de diâmetros (Montgomery/Friedman-1986)
```

#### Geracao dos padrões de CEP (DATA\_CEP.M)

```
% Sao implementadas as equacoes dos padroes de treinamento da rede
% neural conforme descritos no anexo A. Todos os tipos de padroes alem
% do padrao Normal sao gerados automaticamente. Sao considerados
% varios niveis de ruidos e parametros para os seguintes padrões:
```

```
%      Tendencias      Ciclos      Estratificação
%      Sistemáticos    Mistura      Deslocamentos
```

```
%      Algumas variaveis sao geradas nos seguintes arquivos para uso
% posterior:
```

```
%      var_tr.mat
%      t_lim :numero de amostras por carta de controle (default=8)
%      tr_lim :numero de padroes de treinamento
%      pat_tr.mat
%      y: entrada dos padroes de treinamento (t_lim X tr_lim)
%      y_resp: resposta das entradas acima (1 X tr_lim)
%      y_aleat_tr :entrada dos padroes de treinamento em ordem\
%                  aleatoria (t_lim X tr_lim)
%      y_aleat_tr_z :y_aleat_tr com valores preprocessados em zonas
%                  (t_lim X tr_lim)
%      y_resp_aleat_tr :resposta das entradas acima (1 X tr_lim)
```

#### % Algoritmo Basico

```
% BEGIN
%      Implementacao das equacoes dos padroes do Anexo A
%      Aleatorizacao dos Padroes
%      Pre-processamento dos valores em zonas
%      Gravacao dos Padroes em Arquivos
% END
%
```

#### Treinamento da Rede RBF (RBF\_TRAINING.M)

```
%      Este programa deve ser executado apos a geracao dos padroes de
%      treinamento para a classificacao off-line dos tipos de padroes das
%      cartas de controle.
```

```
%      Os pesos e bias da rede RBF sao armazenados para uso posterior
%      em aplicacoes on-line.
```

```
%      Descricao da Função de Treinamento da Função de Base Radial
%      Adaptacao da rotina proposta por Mark Beale, 12-15-93
%      1992-97 by The MathWorks, Inc.)
```

```
%      [W1,B1,W2,B2,TE,TR] = TRAIN(P,T,DP)
```

```

%      P - RxQ matrizes de Q vetores de entrada. P Cartas de controle
%      T - SxQ matrizes de Q vetores de saida. T Resposta do padrao
%      Saidas de TRAIN:
%      W1 - SlxR matriz de pesos para a camada de base radial.
%      B1 - Slx1 vetor de bias para a camada de base radial.
%      W2 - S2xS1 matriz de pesos da camada linear.
%      B2 - S2x1 vetor de bias para a camada linear.
%      NR - Numero de neuronios usados
%      TR - Registro de treinamento: [taxa de erros]
%
%      Parametros para a rede:
%      DP(1): Numero de interacoes para atualizacao do grafico, def= 25.
%      DP(2) - Maximo numero de neuronios, default = # vetores em P.
%      DP(3) - Soma do erro quadratico de saida, default = 0.02.
%      DP(4) - Alargamento da RBF, default = 1.0.
%
% Algoritmo Basico
% BEGIN
%      Le o arquivo de dados com as cartas de controle
%      Define os parametros para a rede Neural
%      Treina a Rede Neural
%      Salva os pesos e Bias da Rede Neural
% END
%
%      Como padroes de entradas foram considerados:
%      - A ordem de apresentacao das Cartas de Controle
%      - Cartas de Controle com e sem pre-processamento
%
%      Os parametros de Setup da rede neural sao basicamente:
%      df: Frequência de atualização do gráfico de erros.
%      mn: Máximo Número de Neurônios
%      eg: SSE
%      sc: Constante de Alargamento para a Função de Base Radial
%      tp = [df mn eg sc];
%
%      No treinamento da RBF foram considerados:
%      Diversas Funcoes de transferencia
%      Diversas Medidas de Similaridade (Distancia entre Vetores)
%      Diversas combinacoes de parametros
%      Discriminacao de saidas da Camada de Base Radial
%      Calculo dos "erros" associados ao vetor
%      Acompanhamento grafico das variaveis

```

#### Teste da Rede RBF (RBF\_TEST.M)

```

% Programa gerador das medidas de performance (tabelas de resultados)
%
%      Este programa avalia os resultados da rede neural treinada off-
%      line para os diversos padroes de CEP segundo a seguinte equacao:
%       $y(t)=u+x(t)+d(t)$  com diversos parametros e ruidos.
%      Os padroes sao gerados simulando um processo real onde uma
%      janela monitora sempre as ultimas entradas.
%      Algumas variaveis sao geradas para a computacao das
%      estatisticas mostradas nas tabelas do Anexo B e para a analise
%      estatistica dos dados:
%
%      RT_pattern=acertos/te_lim          Rate of Target

```

```

%      RNT_pattern=RONT/te_lim;           Rate of Non Target
%      ROF_pattern=falhou/te_lim;         Rate of Fail
%      ATPRL_pattern=RL_pattern/acertos;   ARL para o Target
%      ARLTX_pattern=ATPRL_pattern/RT_pattern; ARL para Taxa Acertos
%      vetorsaidaront                      Padrao erroneamente identificado
%
% Algoritmo Basico
% BEGIN
%      Le os valores dos Pesos, Bias e variaveis salvos no treinamento
%      Gera de Padroes de Teste
%      Calcula as Medidas de Performance
% END

%      Na Geracao dos Padroes de Teste foram considerados:
% - win_lim: Numero de amostras por carta de controle
% (O resultado sera considerado falho se a rede nao conseguir
% classificar um padrao nesse intervalo).
% - Geracao do padrao Normal;
% - Teste dos padroes de CEP
%      Exemplo de codigo em MatLab para Tendencia Crescente:
%      noise=input('noise Tend UP=');
%      alfa=input('alfa Tend UP=');
%      % ou automaticamente:
%      %      noise_tendup=0.05;
%      %      alfa_tendup=0.20;
%      car_noi=100;% cartas para cada noise
%      for inp=1:car_noi;
%          for t=1:win_lim;
%              y_tendup(inp,t)=noise_tendup*randn+(t-
%                  1)*alfa_tendup;
%          end;
%      end;
%      y_resp_tendup=1;
%
%      No calculo das das Medidas de Performance foram considerados
% - Teste de normalidade (Erro tipo I)
%
%      Exemplo de codigo em MatLab para Teste de Normalidade:
%
%      acertos=0;
%      erros=0;
%      te_lim=size(y_normal,2);
%      alvo=y_resp_normal;
%      for j=1:te_lim;
%          teste= simurb(y_normal(:,j),w1,b1,w2,b2);
%          % Função de Teste da Função de Base Radial
%          teste=round(teste);
%          if teste==alvo
%              acertos=acertos+1;
%          else
%              erros=erros+1;
%          end;
%      end;
%      RT_normal=acertos/te_lim;
%      RNT_normal=erros/te_lim;
%      normalidade=[RT_normal,RNT_normal]
%
%
%      Exemplo em MatLab para o Teste do Padrao de Tendencia Crescente

```

```

%
%   acertos=0;
%   lag=0; (Mecanismo para Deslocamento da Janela de pontos)
%   fimARL=0;
%   RONT=0;
%   somaRL=0;
%   falhou=0;
%   RL_tendup=0;
%
%   te_lim=size(y_tendup,2);
%   outros=[2,3,4,5,6,7,8,9];
%
%   for j=1:te_lim;
%       pattern=zones(y_tendup(:,j));
%       %ou pattern=y_tendup(:,j);
%       alvo=y_resp_tendup;
%       while fimARL==0;
%           janela=pattern(1+lag:t_lim+lag);
%           teste= simurb(janela,w1,b1,w2,b2);
%           % Função de Teste da Função de Base Radial
%           teste=round(teste);
%           pertinencia=ismember(outros, teste);
%           if teste==alvo
%               acertos=acertos+1;
%               RL_tendup=RL_tendup+t_lim+lag;
%               fimARL=1;
%           end;
%           if (teste~=alvo)
%               if teste==0 lag=lag+1;end;
%               if max(pertinencia)==1;RONT=RONT+1;fimARL=1;end;
%           end;
%           if lag>=(win_lim-t_lim) falhou=falhou+1; fimARL=1;end;
%       end;
%       fimARL=0;
%       lag=0;
%   end;
%   RT_tendup=acertos/te_lim;
%   RNT_tendup=RONT/te_lim;
%   ROF_tendup=falhou/te_lim;
%   ATPRL_tendup=RL_tendup/acertos;
%   ARLTX_tendup=ATPRL_tendup/RT_tendup;
%   tendup=[noise_tendup, alfa_tendup, RT_tendup, RNT_tendup, ...
%       ... ROF_tendup, ATPRL_tendup, ARLTX_tendup]

```

#### Tratamento do problema da invariância (CICLOS.M)

#### Aplicacao: Video EEG (VIDEOEEG.M)

```

%   Como no programa MAIN.M para os padroes de CEP, as seguintes
%   principais rotinas foram desenvolvidas modificando-se minimamente as
%   rotinas relacionadas com CEP.
%
%   - Rotina Principal (VIDEOEEG.M)
%   - Aquisicao dos dados pelo programa (DATA_EEG.M)
%   - Define Estado do Processo (SET_EEG.M)
%   - Calculo dos Residuos (RESID_EEG.M)
%   - Classificacao de Padroes (PAT_EEG.M)
%   - Apresentacao dos Resultados e Estatisticas (RES_EEG.M)

```



## NÚMEROS DIFUSOS NA ANÁLISE DO SINAL EEG

**Pedro Paulo Balestrassi**

**Alejandro Martins**

**Roberto C. S. Pacheco**

UFSC -Universidade Federal de Santa Catarina

Eng. de Produção e Sistemas - E-mail: pedro@eps.ufsc.br

**Abstract:** *Fuzzy numbers are used to define imprecise classes, to describe imprecise measurements and to derive approximate decisions. This paper describes how fuzzy numbers arise in the automatic processing of electroencephalographic signals. An algorithm for diagnostic classification of the standard 10-20 electroencephalogram is presented and some simulations are shown which exemplify the usefulness of the fuzzy set approach to electroencephalographic diagnosis.*

**Keywords:** *Fuzzy Number, Decision-Making, Electroencephalography*

### 1. Introdução

Uma vasta literatura tem considerado a teoria de números difusos aplicado à área médica. Estudos de falha renal, análise de problemas de insuficiência cardíaca, técnicas de diagnóstico diferencial de hipertensão, análise de vectorcardiografia, tratamento de diabetes, análise da atividade cardíaca, exame clínico de pacientes,... são exemplos de trabalhos publicados [1, 2]. Existe um bem estruturado periódico, o *Biomedical Fuzzy Systems Bulletin*, que representa uma grande tendência das aplicações de conjuntos difusos. Em todos esses trabalhos, diferentes níveis de conhecimento tem sido empregados: em alguns casos os métodos são apenas propostos; alguns exemplos são usados para justificar uma metodologia; finalmente algumas aplicações tem usado o

estágio de completa utilização. O método proposto aqui foi simulado a partir de um banco de dados real obtido por meio de um sistema computadorizado de aquisição do sinal eletrencefalográfico (sinal EEG). A entrada para o sistema foi então o sinal EEG e a saída foi a sugestão de uma possível patologia.

A eletrencefalografia é hoje uma bem definida área de atuação para o médico que investiga qualquer patologia do sistema nervoso central. Ela existe a mais de um século, e tem como principal objetivo a avaliação da atividade elétrica cerebral. O sinal EEG, obtido a partir do córtex, revela na verdade, uma série temporal de amplitudes (da ordem de  $\mu\text{V}$ ) e a morfologia da série obtida está relacionada com as patologias funcionais do cérebro. Os padrões comuns para a análise quantitativa do sinal EEG tem sido elaborados por sociedades como a *International Society for Brain Electromagnetic Topography (ISBET)*, e a *International Society for Neuroimaging in Psychiatry (ISNIP)*, entre outras, que fornecem as “regras” para a aquisição do sinal EEG e sua significação quanto a critérios de diagnóstico.

Tres pontos são abordados nesse artigo, os quais representam os principais problemas de tomada de decisão para esse caso particular: (i) Porque os números difusos são utilizados? (ii) Como foram eles definidos? (iii) Quais tipos de operações são efetuadas sobre esses números e como esses números são comparados?

A seção 2 desse artigo trata as questões (i) e (ii) mostrando onde a imprecisão aumenta e como ela é descrita pelo especialista. Tal imprecisão é naturalmente representada pelos números difusos. A seção 3 que lida basicamente com a questão (iii) ilustra o caminho completo entre a descrição do EEG difuso e a classificação patológica difusa. A seção 3 também indica o problema de comparar quantidades difusas, no sentido de entender porque esse importante problema de estudo reserva algumas dificuldades em um ambiente clínico. Um anexo é colocado ao final, para informar alguns termos básicos e definições de conceitos de eletrencefalografia que são utilizados através do texto.

## 2. Imprecisão

A primeira fonte de imprecisão está no conhecimento médico em si. Vamos considerar por exemplo a descrição dos achados de um EEG quantitativo para um paciente sofrendo de um meningioma na região occipital direita do cérebro: “atividade lenta delta ( $\bar{\Delta}$ ) *alta* (com frequência de 4.0 a 5.5 Hz *aproximadamente*) onde o meningioma foi encontrado, com atividade theta *pronunciada* para o eletrodo O<sub>2</sub>”. Ou o conceito de foco epileptógeno: “O foco epiléptico *não está sempre* no local de máxima positividade ou negatividade, mas está *frequentemente* entre eles, *dependendo* dos valores de voltagem obtidos na vizinhança dos eletrodos e da direção dos dipolos (radial ou tangencial)”[3].

Dois tipos de imprecisão podem ser vistos nessas sentenças: (1) Termos como *alto*, *baixo*, *pronunciada* (ou similarmente *profundo*, *largo*, *relativamente baixo*, etc.) difusamente representam o valor de um atributo do sinal EEG em si; (2) Termos como *frequentemente*, *sempre*, (assim como *em muitos casos*, *predominantemente*, *essencialmente*, *geralmente*, *algumas vezes*, *tipicamente*, etc.) expressam o grau no qual a resposta é capaz de explicar a patologia (grau de caracterização). Termos do tipo (1) são geralmente codificados em valores numéricos. Por exemplo o significado de ondas lentas *alta* poderia ser  $\bar{\Delta} \geq 15.9 \mu V$  [4] ao passo que termos como *comumente*, *usualmente* e outros são assumidos equivalentes a *sempre* ou definitivamente, em oposição a *raramente* ou *alguma vez*, etc. traduzidos em nunca. Nesse sentido, uma mal definida situação torna-se uma imagem da realidade cujo critério pode ser numericamente quantificado em termos exatos (nesse caso, *alto* é um conjunto clássico - “*crisp*”) e um sistema binário (ou ternário) é capaz de representar todos as possíveis graus de caracterização dos estados da natureza (característico/não característico; ou para o caso ternário: característico/possivelmente característico/ não característico).

Duas observações podem ser colocadas nesse ponto: (a) primeiramente, os conjuntos utilizados para representar os valores dos vários parâmetros do sinal EEG são sempre melhor caracterizados por não rupturas do tipo *é* ou *não é*, isto é, não existe precisamente um valor limite entre o *normal* e o *anormal*; (b) em segundo lugar, todos os critérios de caracterização de uma classe patológica levam em conta uma natural

imprecisão nesse grau de caracterização (por exemplo:  $\bar{\Delta} \geq 15.9\mu V$  pode não representar necessariamente uma patologia).

Por essas razões o sistema descrito aqui utiliza conjuntos difusos para representar os valores linguísticos associados aos parâmetros do EEG (por exemplo: uma atividade EEG lenta de amplitude *alta*) assim como para descrever os graus de caracterização dos vários critérios (por exemplo, *frequentemente*).

No sentido de abordar o problema por meio de um algoritmo, algumas limitações foram impostas ao conjunto de termos dos valores linguísticos dos parâmetros e dos valores linguísticos dos graus de caracterização. Cada parâmetro pode assim assumir tres valores, denominados de *Normal*, *Intermediário* e *Anormal* cujas definições variam com o parâmetro em si e com o contexto, isto é, a hipótese do diagnóstico, no qual o parâmetro está considerado. Uma atividade EEG lenta de amplitude *alta* citada naquele contexto é um exemplo de valor anormal.

Por motivo de normatização esses tres conjuntos serão aqui chamados de *Baixo* (*Low - L*), *Médio* (*M*) e *alto* (*High-H*). Algumas vezes os valores *Anormais* serão representados por *Baixo*, outras vezes por *Alto* e raramente por *Médio*. O mesmo pode ocorrer para valores *Normais* ou valores *Intermediários*. Em geral podemos nos referir a um conjunto de valores linguísticos (ou descrições), cujo elemento genérico é:

$$t_{ij}, i = 1, \dots, N; j = 1, \dots, 3,$$

onde  $N$  é o número de parâmetros do EEG, considerados pelo sistema. O índice  $i$  identifica aqui o parâmetro ao qual o valor está associado (por exemplo, *ondas lentas*), assim como o índice  $j$  associa para o valor  $L$ ,  $M$  ou  $H$  (por exemplo, *alto*= $H$  é identificado como  $j=3$ ).

O único meio de definir a relação existente entre o espaço  $T$  de descrição e o espaço  $C$  das classes patológicas é perguntando ao especialista. Em particular, eles podem expressar suas opiniões posicionando, para um certo conjunto de  $n$  medidas dos parâmetros, quais os graus de caracterização de todos os possíveis valores linguísticos de um conjunto com respeito aos tres níveis (*definitivo*, *possível*, *excluído*) de uma certa patologia.

Seja  $c_{pq} \in C^p \subset C$  uma classe genérica, onde  $p$  identifica a patologia e  $q$  identifica seu nível de certeza ( $q=1, \dots, 3$  onde 1 se refere a uma *definitiva* existência de patologia, 2 se refere a uma *possível* existência de patologia e 3 se refere a uma *exclusão* da existência da patologia).

Seja também

$$t^m = t_1^m \dots t_i^m \dots t_{n_p}^m, m = 1, \dots, 3^{n_p},$$

$$t^m \in T_1 \times \dots \times T_i \times \dots \times T_{n_p} = T^p, T_i = \{L_i, M_i, H_i\}$$

onde  $(1, \dots, i, \dots, n_p)$  é uma subsequência de  $(1, 2, \dots, N)$  relacionada a  $p$ , e  $m$  representa a genérica composição do valor dos parâmetros  $n_p$  os quais são traduzidos pelos resultados  $c_{p1}$ ,  $c_{p2}$ ,  $c_{p3}$ . Para cada patologia  $p$ ,  $3^{n_p}$  DOC's são necessários. Esses DOC's representam a relação  $TC_p$  que são as "características de" sobre  $T^p \times C^p$ , relativas à patologia  $p$ .

$TC_p$  é um valor difuso de uma relação difusa pois, conforme já declarado,  $\mu_{TC_p}$  é uma expressão linguística (aqui difusa) assim como *bem caracterizada*, *mal caracterizada*, etc. Cinco diferentes termos tem sido utilizados pelos médicos para expressar suas opiniões. São elas: *Muito baixo* (very low- $vl$ ), *baixo* (low- $l$ ), *médio* ( $m$ ), *alto* (high- $h$ ) e *Muito alto* (very high- $vh$ ). Por exemplo, o conjunto particular dos valores dos parâmetros:

Densidade Espectral  $h$  em regiões occipitais

Mobilidade do sinal  $vl$  em regiões occipitais

Existência de Dipolo  $l$

mostram uma descrição da classe genérica "possível patologia X".

Sumarizando, qualquer subconjunto  $t^m = t_1^m \dots t_i^m \dots t_{n_p}^m$  de valores de parâmetros é chamado de descrição composta do EEG. Um DOC linguístico para a patologia  $p$  é então a opinião de um especialista para cada descrição (simbolizada por  $p$ ), onde cada DOC é referido em termos do conjunto  $\{vl, l, m, h \text{ e } vh\}$  predefinidos no intervalo  $I=[0,1]$ . Esses DOC's, mostrados na figura 1, são números difusos trapezoidais.

Números difusos são também utilizados para representar os valores linguísticos

$t_{ij} \in \{L_i, M_i, H_i\}$  dos parâmetros. O especialista é questionado a indicar

aproximadamente seus valores de fronteira os quais são também deduzíveis da literatura técnica. Ele/ela é também capaz de identificar de alguma forma a extensão da precisão em torno desses valores de fronteira. As indicações podem ser diferentes entre diferentes especialistas, como se verifica na prática, e assim os experimentos podem ser conduzidos no sentido de se obter um valor ponderado para  $t_{ij}$ . Isso é realmente muito difícil e consome muito tempo na prática, devido ao grande número de conjuntos a serem definidos. A curva em forma de S tem sido encontrada (conforme exemplifica a figura 2), mas nada suporta essa especial escolha se comparada a outras definições, como por exemplo linear (isto é, triangular ou trapezoidal) ou exponencial. Contudo a escolha não é crítica, tanto em termos da pouca importância de pequenas diferenças entre dois valores particulares de pertinência quanto em termos da relativamente curta região de transição se comparada a diferenças entre valores numéricos consecutivos (o nível de quantificação para medidas de amplitude é da ordem de  $5\mu\text{V}$ , o intervalo de amostragem das medidas, dependendo do conversor, segue a taxa de Nyquist e deve ser da ordem de 2 ms). O que realmente interessa é a identificação dos limites das áreas de transição, não a sua representação exata.




Figura 1 - Graus de caracterização (DOC's)




Figura 2 - Valores linguísticos para o parâmetro latência de uma espícula

Duas fontes de imprecisão tem sido discutidas até agora: os valores linguísticos  $t_{ij}$  utilizados para descrever os parâmetros, e a relação  $TC_p$  entre as descrições das composições linguísticas e as classes alternativas sobre as quais se vai decidir. Ambas dessas quantidades ( $t_{ij}$  e DOC's) tem sido definidas pelo especialista. As *distribuições de possibilidade* procuram abordar outros tipos de imprecisão mas não serão abordadas aqui.

### 3. Fundamentos do Algoritmo de Diagnóstico

O computador extrai do sinal EEG  $N$  valores numéricos ou medidas dos parâmetros,  $v_i \in V_i \subset \mathfrak{R}$ ,  $i = 1, \dots, N$ . Cada valor está relacionado diretamente ao parâmetro mensurado (por exemplo uma determinada densidade de frequência em  $F_7$ ) ou para um parâmetro derivado (por exemplo uma determinada densidade de potência em  $F_7$ ). A primeira aplicação do conhecimento médico para diagnosticar um problema é identificar os subconjuntos de parâmetros necessários e suficientes para avaliar o EEG com respeito a uma classe de patologia específica  $c_p$ . Sejam  $v_i$ ,  $i = 1, \dots, n_p < N$ , os valores numéricos considerados nessa situação. Devido aos inevitáveis erros nessa avaliação, os  $v_i$ 's são convertidos em sua representação difusa  $v_i$ , obtida conforme a distribuição de possibilidade a partir do conhecimento do histograma de erros. A representação do EEG passa agora a partir de um vetor  $n$ -dimensional  $v^k = (v_1^k, \dots, v_i^k, \dots, v_{n_p}^k)$  pertencentes ao subespaço  $V^p = V_1 \times \dots \times V_i \times \dots \times V_{n_p}$  das medições para um ponto difuso  $n_p$ -dimensional  $v^k = (v_1^k, \dots, v_i^k, \dots, v_{n_p}^k)$  do espaço  $P^p(V)$  de valores difusos, onde  $P^p(V) = P(V_1) \times \dots \times P(V_i) \times \dots \times P(V_{n_p})$  e  $P(V_i)$  é o conjunto de todos os subconjuntos difusos de  $V_i$ .

No sentido de usar os valores difusos de uma relação difusa  $TC_p$  sobre  $T^p \times C^p$  definida pelo conhecimento médico, cada valor difuso composto  $v^k$  deve ser transformado em termos do conjunto linguístico  $T^p$ . Isso é consumado diretamente pela relação  $VT_p$  sobre  $P^p(V) \times T^p$  que define a verdade relativa da proposição “a descrição é  $t^m$ ” dada a evidência “a descrição é  $v^k$ ”. Isso é também chamado de compatibilidade de  $v^k$  com  $t^m$ .

Seja a compatibilidade dos valores difusos  $v_i^k$  com os valores linguísticos  $t_i^m$  o conjunto difuso  $\tau(v_i^k, t_i^m)$  sobre  $[0, 1]$  definido por Zadeh[6]

$$\mu_{\tau}(x) = \sup_{u \in U: x = \mu_{v_i^k}^m(u)} \mu_{v_i^k}(u) \quad \forall x \in [0, 1]$$

onde  $U$  é o universo do discurso de ambos  $v_i^k$  e  $t_i^m$ . Assim os valores difusos da relação difusa  $VT_p$ , “transformado em”, é expressa por

$$\tau(v_i^k, t_i^m) = m \tilde{t}^m[\tau(v_1^k, t_1^m), \dots, \tau(v_{n_p}^k, t_{n_p}^m)] \quad \forall m \in \{1, \dots, 3^{n_p}\}$$

onde  $m\tilde{I}m$  é a operação difusa *mim* definida por Dubois e Prade [5].

Queremos agora avaliar o grau para o qual  $v^k$  é sugestivo de  $c_{pq}$ , conhecendo quão boa é a transformação de  $v^k$  em  $t^m$  e quanto  $t^m$  é característico de  $c_{pq}$ . Esse grau pode ser facilmente obtido como uma relação  $VC_p$ , “*sugestivo de*”, sobre  $P^p(V) \times C^p$ , a qual é obtida diretamente da composição de  $VT_p$  com  $TC_p$ :  $VC_p = VT_p \circ TC_p$ .

$VC_p$  é aqui definido por  $\mu_{VC_p}(v^k, c_{pq}) = m\tilde{a}x_m m\tilde{I}m[\mu(v^k, t^m), \mu(t^m, c_{pq})]$

onde similarmente ao  $m\tilde{I}m$ ,  $m\tilde{a}x$  é uma operação *max* difusa também definida por [7].

A força da relação entre  $v^k$  e  $c_{pq}$  ( $q=1, \dots, 3$ ) é portanto assumida ser a força da cadeia mais forte  $v^k -- t^m -- c_{pq}$ ,  $m=1, \dots, 3^p$ , com a força da cadeia sendo o elo mais fraco entre  $v^k -- t^m$  e  $t^m -- c_{pq}$ .

Como resultado dos procedimentos descritos até agora, tres conjuntos difusos

$$a_{pq} = \mu_{VC_p}(v^k, c_{pq}) \quad q=1, \dots, 3,$$

são obtidos para uma classe genérica  $p$ , dado o subconjunto de valores de parâmetros relacionado  $v^k$ , medidos a partir do sinal EEG. Cada conjunto difuso  $a_{pq}$  representa a força da evidência da alternativa de diagnóstico  $c_{pq}$ . A escolha entre as alternativas mutuamente excludentes  $c_{p1}$ =*patologia definitiva*,  $c_{p2}$ =*possível patologia* e  $c_{p3}$ =*nenhuma patologia*, é então executada na base dos tres conjuntos  $a_{p1}$ ,  $a_{p2}$  e  $a_{p3}$ .

Os problemas encontrados na comparação de valores difusos são bem conhecidos e continuam a ser tratados na literatura. A opção por uma análise envolvendo *Ordenamento* foi escolhida e pode ser melhor avaliada em [8].

#### 4. Exemplo

Vamos considerar agora um sinal EEG (digitalizado a partir do sistema de EEG Quantitativo Neuromap), que simula uma patologia hipotética. A matriz contendo as principais medidas dos parâmetros extraídos desse sinal é mostrada na tabela 1. Tais medidas são obtidas por meio de resultados de uma análise temporal, espacial e frequencial do sinal EEG conforme ilustra a figura 4 no anexo. O uso do algoritmo da FFT (Fast Fourier Transform) é fundamental nesse tipo de análise.



Se nós enfocarmos uma determinada patologia denominada genericamente por PAT, então temos que relacioná-la ao seu conhecimento médico como exemplificado na tabela 2, que define a relação  $TC_{PAT}$  entre os parâmetros 45 “Razão da atividade Delta/Theta fora do padrão em dois pontos das regiões Frontal, Parietal, Occipital e Temporal ” e o parâmetro 49 “Latência de espícula nas mesmas regiões” e também o conjunto das classes patológicas “PAT definitivo”, “PAT possível” e “Nenhum PAT”.

Por essa tabela podemos observar que “PAT definitivo” é definido como:

Razão da atividade Theta/Delta Alta (H45),

Latência de espícula Alta (H49),

onde o DOC para “PAT definitivo” é muito alto (vh=very high) enquanto que é muito baixo (vl=very low) para “PAT possível” e “Nenhum PAT” (última linha da tabela 2).

	Frontal								Temporal				Central			Parietal			Occipital		
	Fp1	Fp2	F3	F4	F7	Fz	T8	T3	T4	T5	T6	C3	C4	Cz	P3	P4	Pz	O1	O2	Oz	
Delta																					
Theta																					
Alfa																					
Beta1																					
Beta2																					
Caractograma																					
Coerência																					
Alfa/Theta																					
Theta/Delta								97	49												
Espículas								35	30												
ZSM																					
teste t																					
teste F																					

Tabela 1- Matriz de medidas para o sinal EEG número 19

$t^m$		$c_{pq}$			
par 45	par 49	definitivo PAT	possível PAT	nenhum PAT	
L <sub>45</sub>	L <sub>49</sub>	vl	vl	vh	
L <sub>45</sub>	M <sub>49</sub>	vl	l	h	
L <sub>45</sub>	H <sub>49</sub>	l	m	l	
M <sub>45</sub>	L <sub>49</sub>	l	l	h	
M <sub>45</sub>	M <sub>49</sub>	l	h	l	
M <sub>45</sub>	H <sub>49</sub>	m	vh	l	
H <sub>45</sub>	L <sub>49</sub>	m	m	l	
H <sub>45</sub>	M <sub>49</sub>	vh	h	l	
H <sub>45</sub>	H <sub>49</sub>	vh	vl	vl	

Tabela 2- Tabela para PAT

Com respeito ao parâmetro 45, sua compatibilidade com L, M e H são os valores

$\tau_{L45} = \tau_{M45} = 0, \quad \tau_{H45} = 1$  (valores “crisp”)

donde a compatibilidade global de  $v^k = (49, \sim 30)$  com  $t^m(m=1,...,3^2)$  são dados na tabela 3.

$t^m$	$v$
L <sub>45</sub>	L <sub>49</sub>
L <sub>45</sub>	M <sub>49</sub>
L <sub>45</sub>	H <sub>49</sub>
M <sub>45</sub>	L <sub>49</sub>
M <sub>45</sub>	M <sub>49</sub>
M <sub>45</sub>	H <sub>49</sub>
H <sub>45</sub>	L <sub>49</sub>
H <sub>45</sub>	M <sub>49</sub>
H <sub>45</sub>	H <sub>49</sub>

Tabela 3 - compatibilidade




Figura 3 - Força da evidência

Da composição de  $\mu_{VT_{DAT}}(v^k, t^m)$  da tabela 3 com a  $\mu_{CT_{DAT}}(t^m, c_{pq})$  da tabela 2, é agora possível obter os tres valores  $a_q = \mu_{VC_{DAT}}(v^k, c_q)$   $q = 1, \dots, 3$ , que representam “PAT definitivo”, “PAT possível” e “Nenhum PAT”. Esses tres conjuntos são representados graficamente na figura 3. Sua análise revela uma suave preferência por “PAT possível” sobre “PAT definitivo”. “Nenhum PAT” é claramente excluída da escolha.

Esse resultado é também genericamente sugerido pela comparação de outros métodos de implementação existentes na literatura. Os métodos de Yager, Dubois-Prade, Chen, Chang, Adamo, entre outros podem e devem ser usados para efeitos comparativos

O decisor (o neurologista ou o eletrencefalografista) confrontado com esse caso, independentemente dos procedimentos computadorizados, pode também emitir uma sentença de “PAT possível” com maior tendência para “anormal” do que para “normal”.

## 5. Conclusão

O exemplo anterior procurou mostrar a principal utilidade dos números difusos na tomada de decisão do diagnóstico eletrencefalográfico, isto é, a sua habilidade em descrever a situação como ela é, sem assumir conclusões clássicas (“crisps”). Se os valores de todos os parâmetros envolvidos na decisão são bem definidos como normais,

anormais ou intermediários, então as tres classes alternativas podem ser ordenadas de acordo com os DOC's associados pelo especialista a partir de uma tabela de diagnóstico.

As medidas numéricas também são passíveis de erro. A metodologia descrita aqui não é obviamente capaz de corrigir erros grosseiros, entretanto pequenos desvios do verdadeiro valor podem ser compensados pela suave mudança de escolha devido a representação difusa de alternativas otimizadas. O computador é não somente capaz de sugerir uma alternativa ótima como também pode medir o quão melhor uma alternativa é melhor do que outras. Quando os conjuntos finais ( ou seus índices associados) usados na comparação estão muito próximos, então o usuário deve ser avisado de que a situação não é clara e que uma pequena variação na avaliação de alguns parâmetros é suficiente para mudar uma escolha sugerida. Em nossa opinião esse resultado é claramente superior a uma sentença do tipo *sim/não* incapaz de estabelecer o quão longe de um ponto crítico a decisão é tomada.

O problema ainda carece de uma melhor representação para o usuário no espaço da decisão final. Tanto a representação gráfica (como da figura 3) como os diversos índices não satisfazem completamente ao especialista, que pode julgar tais saídas como incômodas. Sentenças linguísticas representando a situação atual tem provavelmente melhor aceitação e entendimento do que uma sugestão gráfica ou numérica, mas a translação, por exemplo da figura 3 para uma descrição linguística não é tão simples como pode parecer. Uma medida linguística de distância pode provavelmente dar uma boa solução para esse problema, mas uma métrica correta deve ser utilizada. Tal métrica somente pode ser encontrada a partir de uma adequada casuística, e isso é um trabalho a ser feito.

## 6. Bibliografia

- [1] Adlassnig, K.P.- **A survey on medical diagnosis and fuzzy subsets**, in: Gupta, N.M./Sanchez, E. *Approximate Reasoning in Decision Analysis* (Amsterdam,1982);
- [2] Degani, R./Bortolan G.- **Fuzzy numbers in Computerized Electrocardiography** - Fuzzy sets and Systems 24 (Amsterdam, 1987);

- [3] Maurer, K./Dierks, T - **Atlas of Brain Mapping** - Springer Verlag (Berlim, 1991);
- [4] Duffy, F.H./Iyer, V.G./Surwillo, W.W. - **Clinical Electroencephalography and Topographic Brain Mapping** - Springer Verlag (New York, 1989);
- [5] Dubois, D/Prade, H.- **On several representations of an uncertain body of evidence** -in: Gupta, N.M./Sanchez, E. *Information and Decision Processes* (Amsterdam, 1982);
- [6] Zadeh, L. A.- **Outline of a New Approach to the Analysis of Complex Systems and Decision Process**, IEEE Transactions on Systems, Man and Cybernetics, 3, 28-44, 1973.
- [7] Dubois, D/Prade, H.- **Fuzzy Sets and Systems: Theory and Applications** - (Academic Press, New York, 1980);
- [8] Baas, S./Kwakernaak - **Rating and Ranking of Multi-aspect alternatives using fuzzy sets** - Automatica vol. 13, 47-58 (New York-1977);
- [9] Klir, George J./Yan, Bo- **Fuzzy Sets and Fuzzy Logic: theory and applications**, Prentice-Hall, Inc. 1995.

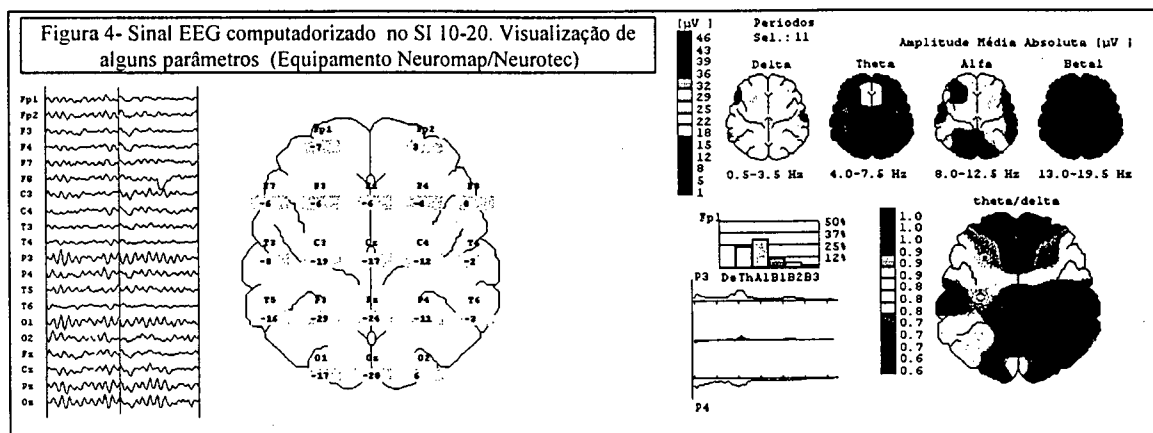
## 7. Anexo: Um resumo sobre sinais EEG

O eletrencefalograma é um gráfico obtido a partir de forças elétricas produzidas pelo cérebro. Devido ao corpo poder conduzir correntes elétricas, tais forças podem ser captadas na superfície cerebral por meio de eletrodos instalados no couro cabeludo. O EEG padrão utiliza convencionalmente um sistema de 20 eletrodos dispostos segundo um sistema internacional denominado SI 10-20, como mostra a figura 4. Tal figura mostra também o sinal EEG obtido segundo uma determinada referência.

O sinal EEG é normalmente registrado em um papel com 8 canais (existem aparelhos com 12, 20, 24 ou mais canais). Algumas características desse sinal são: (i) série temporal randômica e estocástica de amplitudes (na ordem de  $\mu V$ ), (ii) frequência de 0 a 70 Hz (geralmente são usados filtros para frequências maiores que 32 Hz)

As principais alterações do sinal EEG vistas em um exame eletrencefalográfico podem ser geralmente divididas em cinco categorias de anormalidades [4]:

- 1) Ritmos de fundo: (a) Ritmos Alfa: Encefalopatias tóxicas, metabólicas e infecciosas de diversas etiologias; demência; hipertireoidismo, lesões, coma,... (b) Ritmo Beta: lesões corticais destrutivas, hematomas, efeitos de droga ...(c) Outras: morte cerebral, hipoxia ...
- 2) Padrão do sono: hematomas subdurais, síndrome de Sturge-Weber, lesões estruturais, etc...
- 3) Baixa atividade: IRDA, FIRDA, OIRDA, acidentes cerebrovasculares, tumores intracranianos, encefalopatias focais, encefalopatias difusas, ...
- 4) Paroxísmos epileptógenos: Descargas epileptiformes, Spikes, Sharp-wave, Polyspikes, Hipsarritmia, padrões ictal, sincronia bilateral secundária, Ritmo Breach, SREDA, ...
- 5) Padrões paroxísticos periódicos: SSPE, Síndrome de Jakob-Creutzfeldt, PLEDS, etc...



# **INTELIGÊNCIA ARTIFICIAL APLICADA AO CONTROLE ESTATÍSTICO DE PROCESSOS EM SISTEMAS AUTOMATIZADOS DE MANUFATURA**

**Robert Wayne Samohyl**

UFSC - Departamento de Engenharia de Produção e Sistemas - e-mail: [samohyl@eps.ufsc.br](mailto:samohyl@eps.ufsc.br)

**Pedro Paulo Balestrassi**

EFEI –Escola Federal de Engenharia de Itajubá - e-mail: [pedro@eps.ufsc.br](mailto:pedro@eps.ufsc.br)

**Fernando Ostuni Gauthier**

UFSC – Departamento de Engenharia de Produção e Sistemas - e-mail: [gauthier@eps.ufsc.br](mailto:gauthier@eps.ufsc.br)

**Abstract:** *This study aims to present a focus on Statistical Process Control (SPC) by using Applied Intelligence techniques as Neural Networks and Fuzzy Logic. The SPC is a powerfull tool extensively used in Industrial Engineering (Manufacturing Systems) and the adoption of Automated Manufacturing Systems has been increasing in recent years due to a greater demand for products diversification, with a higher quality and in a shorter delivery time. The quality control of the process in such situations demands flexible and intelligent quality control systems. So, it is proposed the presentation of SPC through the use of Applied Intelligence techniques according to the following steps:*

- *To simulate of an Automated Production Process;*
- *To envelope pre-processing techniques and Neural Networks;*

**Area:** *Controle Estatístico de Qualidade*

**Keywords:** *SPC, Applied Intelligence, Neural Networks*

## **1. Introdução**

Esse trabalho descreve um exercício em Controle Estatístico de Processos (CEP) em um sistema automatizado de manufatura onde são utilizadas técnicas de Inteligência Artificial (IA). Esse tipo de sistema tem apresentado um enorme crescimento e a adoção de agentes inteligentes no desempenho de algumas funções como reconhecimento de padrões e diagnóstico de problemas, tarefas até então feitas pelo ser humano, certamente será a tônica dos próximos anos.

Na próxima seção serão vistos alguns conceitos fundamentais de IA. Na seção 3 o CEP será resumidamente apresentado, abordando principalmente o reconhecimento de padrões não aleatórios das cartas de controle. A seção 4 se ocupará com a

contextualização do CEP em sistemas automatizados de manufatura em termos de IA. A construção de uma base de dados para treinamento e teste de um agente será descrito na seção 5. A seção 6 apresentará a rede neural fuzzy-Artmap, um algoritmo, além de algumas técnicas de pré-processamento. Na seção 7 a medida de desempenho abordando *ARL (Average Run Length)* é descrita e na seção 8 alguns resultados são apresentados.

Para esta aplicação foram geradas 3200 cartas de controle usando simulação (cada carta com 60 pontos) e os resultados em termos de reconhecimento de padrões mostraram ser satisfatórios.

## 2. Inteligência Artificial (IA)

A IA tem sido definida como “um campo de estudo que procura explicar e simular o comportamento inteligente em termos de processos computacionais” (Schalkoff, 1990) ou ainda como “um ramo da ciência da computação que se preocupa com a automação do comportamento inteligente”(Luger&Stubbs, 1993). Nesse sentido, a IA é categorizada como um sistema que atua racionalmente e é vista como o estudo e construção de agentes racionais.

Um agente é algo que pode perceber seu meio ambiente através de sensores e atuar sobre esse ambiente através de alguns mecanismos. Um agente racional é um agente que toma a ação correta (Russel&Norvig, 1995). Uma medida de desempenho é o critério que determina o quão bom é o agente racional e a tarefa da IA é projetar um programa agente que implemente um mapeamento entre a percepção do meio ambiente e uma referida ação. Esse programa irá rodar em algum tipo de arquitetura e o relacionamento entre agente, arquitetura e programa pode ser sintetizado pela expressão:

Agente = Arquitetura+Programa.

## 3. Aplicação

Uma aplicação que está perfeitamente inserida nesse contexto se refere ao Controle Estatístico de Processos (CEP) em Sistemas Automatizados de Manufatura. As Cartas de Controle são aqui as mais importantes e também as mais conhecidas ferramentas.

contextualização do CEP em sistemas automatizados de manufatura em termos de IA. A construção de uma base de dados para treinamento e teste de um agente será descrito na seção 5. A seção 6 apresentará a rede neural fuzzy-Artmap, um algoritmo, além de algumas técnicas de pré-processamento. Na seção 7 a medida de desempenho abordando *ARL (Average Run Length)* é descrita e na seção 8 alguns resultados são apresentados.

Para esta aplicação foram geradas 3200 cartas de controle usando simulação (cada carta com 60 pontos) e os resultados em termos de reconhecimento de padrões mostraram ser satisfatórios.

## 2. Inteligência Artificial (IA)

A IA tem sido definida como “um campo de estudo que procura explicar e simular o comportamento inteligente em termos de processos computacionais” (Schalkoff, 1990) ou ainda como “um ramo da ciência da computação que se preocupa com a automação do comportamento inteligente”(Luger&Stubbs, 1993). Nesse sentido, a IA é categorizada como um sistema que atua racionalmente e é vista como o estudo e construção de agentes racionais.

Um agente é algo que pode perceber seu meio ambiente através de sensores e atuar sobre esse ambiente através de alguns mecanismos. Um agente racional é um agente que toma a ação correta (Russel&Norvig, 1995). Uma medida de desempenho é o critério que determina o quão bom é o agente racional e a tarefa da IA é projetar um programa agente que implemente um mapeamento entre a percepção do meio ambiente e uma referida ação. Esse programa irá rodar em algum tipo de arquitetura e o relacionamento entre agente, arquitetura e programa pode ser sintetizado pela expressão:

Agente = Arquitetura+Programa.

## 3. Aplicação


Uma aplicação que está perfeitamente inserida nesse contexto se refere ao Controle Estatístico de Processos (CEP) em Sistemas Automatizados de Manufatura. As Cartas de Controle são aqui as mais importantes e também as mais conhecidas ferramentas.



Elas são úteis em determinar se um processo está se comportando como desejado ou se existem algumas causas não naturais de variação interagindo no processo. Um processo está fora de controle se um ponto (por exemplo, uma medida obtida de um sensor em um processo de manufatura automatizado) situa-se fora dos chamados limites de controle ou uma série de pontos exibem um comportamento não natural (também conhecido como padrão não aleatório).

A análise dos padrões não aleatórios é um dos mais relevantes aspectos do CEP. Esses padrões fornecem valiosas informações relacionadas com a melhoria de um processo. Existe uma vasta literatura técnica sobre tais padrões que associam frequentemente um conjunto específico de causas assinaláveis a um determinado padrão não natural em uma carta de controle. A identificação desses padrões pode fortemente estreitar o conjunto de causas que devem ser investigadas em possíveis problemas e assim o tempo de diagnóstico pode ser substancialmente reduzido.

Desde a sua formal concepção em 1924 por Walter Shewhart, numerosas regras suplementares conhecidas como *Runs Tests* ou *Zone Tests* (Western Electric 1958, Nelson 1984) tem sido propostas para analisar os padrões não aleatórios das cartas de controle. A figura 1 mostra um desses conjuntos de regras clássicas. Essas regras foram desenvolvidas para assistir os operadores na detecção de padrões não naturais. Contudo, a interpretação dos dados de um processo qualquer ainda permanece difícil pois isso envolve aspectos de reconhecimento de padrões que frequentemente leva em consideração a experiência do analista em determinar se um padrão não natural existe ou não.



- 1) 1 ponto acima do limite de controle
- 2) 2 pontos em 3 consecutivos acima de 2 desvios
- 3) 4 pontos em 5 consecutivos acima de 1 desvio
- 4) 7 pontos consecutivos além da linha média
- 5) 6 pontos consecutivos crescentes ou decrescentes
- 6) 8 pontos crescentes ou decrescentes em 10
- 7) 2 pontos consecutivos com diferença de 4 desvios

Figura 1: *Runs Tests* clássico

4. A Aplicação em Termos de IA

Para a aplicação anteriormente sugerida um agente racional pode ser descrito em termos de IA de acordo com a tabela 1.

Tipo de Agente	Sistema de reconhecimento de padrões não aleatórios em gráficos de CEP.
Percepção	Medidas de um item de controle obtidas em tempo real por meio de sensores.
Ação	Sugerir causas de possíveis problemas de produção a um operador, atuar no processo interrompendo a produção, acionar controladores, sinalizar, etc...
Objetivo	Reconhecer determinados tipos de padrões em séries temporais e suas possíveis causas.
Ambiente	Sistemas de manufatura automatizados

Tabela 1: Um Agente e sua descrição em termos de IA.

O ambiente no qual este agente está definido possui as propriedades dadas na tabela 2.

Acessível	Os sensores detectam todos os aspectos que são relevantes para a escolha da ação a ser tomada.
Determinístico	O próximo estágio do ambiente é completamente determinado pelo estado atual e ações selecionadas pelo agente
Episódico	Cada episódio consiste da percepção e ação de um agente
Semi-Dinâmico	O ambiente não muda com o passar do tempo mas o desempenho do agente sofre alterações
Discreto	Existe um número limitado de percepções e ações a ser tomadas pelo agente

Tabela 2: As Propriedades do Ambiente do Agente

O programa agente a ser implementado é do tipo *reflexo simples* que usa conexões do tipo *regra if-then* ou *regra condição-ação* e está representado na figura 2. Uma das mais importantes técnicas para a percepção do ambiente consiste hoje nas Redes Neurais e a ação a ser tomada pode ser efetuada a partir de um Sistema Especialista avaliando a *regra condição-ação*. Temos assim nesse caso um agente usando um programa híbrido.

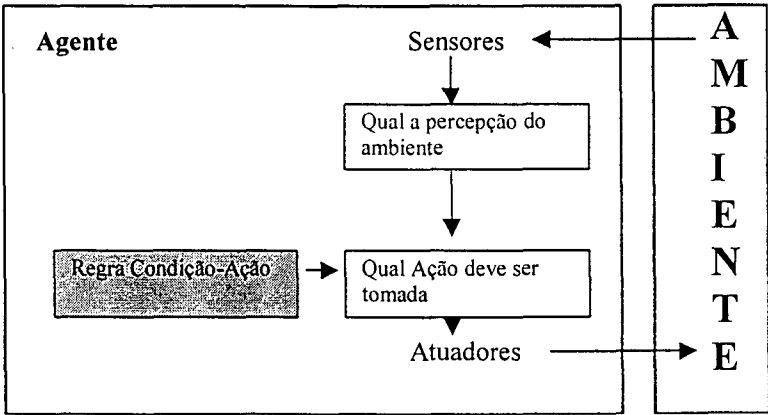


Figura 2 – Agente do tipo Reflexo Simples

No contexto da aplicação os seguintes passos exemplificam a atuação do agente descrito:

1. 60 medições são obtidas a partir de um sensor em um processo de manufatura qualquer;
2. Uma rede neural anteriormente treinada identifica um padrão aleatório do tipo *tendência*
3. Um Sistema Especialista identifica a partir de um conhecimento prévio que a tendência detectada anteriormente está relacionada com a deterioração da matéria-prima;
4. Um sistema de alarme indica que a matéria prima deve ser averiguada.

Guo&Dooley (1992) descreve que o CEP pode ser pensado como consistindo de vários estágios (*observação, avaliação diagnóstico, decisão e implementação*) os quais ele define como *Janelas de Qualidade*. Assim, o processo é *observado* através dos dados do produto e então a estabilidade do processo é *avaliada* por meio dos padrões não aleatórios das cartas de controle. Um padrão não aleatório implica em um *diagnóstico* de uma possível causa para o comportamento não aleatório e uma vez identificada a causa, uma *decisão* deve ser tomada no sentido de uma ação corretiva que é então *implementada*.

Devido ao caráter didático, o restante desse trabalho se ocupará somente com o estudo da fase de *avaliação* deixando as outras fases para posteriores estudos.

## 5. Construção do Banco de Dados

Na geração dos padrões aleatórios e não-aleatórios de CEP, para o treinamento e teste das redes neurais, os principais cuidados a serem tomados estão relacionados com a sua boa representatividade das situações reais dos padrões de um processo. Deve-se ter assim um bom balanceamento de padrões para a entrada das redes neurais durante o treinamento e teste e sobretudo os padrões não devem mostrar ambigüidade no sentido de fornecer uma boa indicação de causas assinaláveis de variação, auxiliando assim o operador ou possibilitando a inserção de Sistemas Especialistas numa posterior etapa de tomada de decisão. A figura 3 mostra um processo de geração do banco de dados de treinamento onde foi usada a orientação dos trabalhos de Hwang&Hubele (1993), Guo&Dooley (1992) e Tontini(1995).




Figura 3: Geração do conjunto de treinamento

Nesse esquema são geradas 60 amostras de uma distribuição normal  $N(0,1)$  constituindo um gráfico de CEP. Em seguida é feito um teste de normalidade sobre esse gráfico usando as cartas de Shewhart para pontos individuais, a Soma dos Quadrados dos Desvios e também Carta CUSUM. Caso o processo não seja normal devido a um desses 3 testes uma nova carta deve ser gerada. Em caso de normalidade um padrão não natural é gerado por meio de algumas equações clássicas e há uma consecutiva inserção de pontos não naturais no gráfico de controle normal até que o padrão não natural seja identificado pelo mesmo teste de normalidade. Esse deslocamento tem o intuito de simular um processo real onde os padrões não naturais vão surgindo com o tempo. O deslocamento da janela de pontos é um mecanismo de inserção de um padrão não natural em um padrão natural. Por meio desse mecanismo, pode ser obtido o ARL (*Average Run Length*) e o número de amostras necessárias para a determinação do reconhecimento de padrões não naturais (Mittag 1993). Caso o padrão tenha sido identificado, ele é armazenado em um arquivo e o processo todo é reiniciado. Caso o padrão não seja identificado pelos testes, um novo padrão não natural é gerado até a sua identificação.

Dessa forma todo o conjunto de treinamento é gerado automaticamente abrangendo um grande escopo de padrões não naturais. Sendo gerado *off line*, tal banco de dados representa também um abrangente escopo de possibilidades de causas assinaláveis existentes em um processo automatizado de manufatura. Para treinamento não supervisionado, a obtenção desse banco de dados provavelmente poderia ser obtido por uma implementação em *hardware* usando placas de DSP (*Digital Signal Processing*), que conjuntamente com um conversor analógico/digital, permite a implementação de inúmeras ferramentas matemáticas como FFT, Ondaletas, etc.

Como resultado desse processo de geração, foram obtidos então 1400 padrões, divididos nas seguintes categorias:

Desvios da média: com amplitude de $\pm 1\sigma$ e $\pm 1.5\sigma$	(400)
Mistura: com amplitude de $1\sigma$ e $1.5\sigma$	(200)
Ciclos: com amplitude de $1\sigma$ e $1.5\sigma$ e período 20	(200)
Sistemáticos: com amplitude de $1\sigma$ e $1.5\sigma$	(200)
Diminuição da variabilidade: com amplitude de $0.5\sigma$ e $0.7\sigma$	(200)
Normais: $\sim N(0,1)$	(200)
	1400

A equação que define a geração dos números aleatórios pode ser sintetizada pela expressão:  $y(t) = \mu + a(t)$  com  $\mu=0$  e ruído  $a(t)$  com média zero e variância  $\sigma^2=1$ . As equações geradoras dos padrões não aleatórios estão bem representadas em Tontini (1995).

Para que se consiga uma boa representatividade dos padrões gerados, não basta que eles sejam gerados por suas respectivas equações. É preciso garantir que algumas condições iniciais sejam satisfeitas. Não raro ocorre que uma carta de controle gerada aleatoriamente segundo uma distribuição normal apresenta padrões não naturais. Os testes a seguir tem a função de monitorar esse problema.

- a) *Teste de Shewhart para Pontos Individuais*
- b) *SSQ<sub>i</sub> (Soma dos Quadrados dos Resíduos)*
- c) *CUSUM (Gráfico de Somas Acumuladas - Cumulative Sums)*

O conjunto de treinamento e de testes dos padrões de CEP diferem ligeiramente no sentido de ampliar a sensibilidade de reconhecimento dos padrões. No conjunto de testes não foram incluídos os padrões de normalidade deixando para o sistema a identificação do padrão normal quando todos os outros testes falharem.

Como resultado desse processo de geração, foram obtidos 1800 padrões, divididos nas seguintes categorias:

Desvios da média: com amplitude de $\pm 1\sigma$ , $\pm 1.5\sigma$ e $\pm 2\sigma$	(600)
Mistura: com amplitude de $1\sigma$ , $1.5\sigma$ e $2\sigma$	(300)
Ciclos: com amplitude de $1\sigma$ , $1.5\sigma$ e $2\sigma$ e período 20	(300)
Sistemáticos: com amplitude de $1\sigma$ , $1.5\sigma$ e $2\sigma$	(300)
Diminuição da variabilidade: com ampl. de $0.5\sigma$ , $0.6\sigma$ e $0.7\sigma$	(300)
	1800

Foi considerado na geração dos padrões de teste, no deslocamento da janela de pontos, o valor da função *ARL*. A função *ARL* é um poderoso instrumento que descreve a *performance* das cartas de controle (a CCO- Curva Característica de Operação também pode fazer isso). Tal função representa a expectância da variável aleatória *Run Length* que é o número de amostras que ocorrem entre duas intervenções consecutivas em um processo. A função *ARL* de uma carta de controle mostra como os valores de *ARL* dependem do estado do processo. Quando um processo está sob controle, esta função deveria possuir altos valores e para processos fora de controle, a função deveria apresentar baixos valores.

## 6. Redes Neurais

O banco de dados gerado nos moldes do capítulo anterior é agora experimentalmente testado com respeito ao reconhecimento dos padrões das cartas de controle de CEP. Em sua primeira parte experimental foi utilizada a rede neural Fuzzy ARTMAP. Os valores dos parâmetros da rede, foram selecionados a partir da literatura existente (Tontini,1995), onde a técnica de *Projetos de Experimentos* foi extensivamente utilizada.

Aplicados como entrada das redes neurais sem nenhum tipo de pré-processamento, as cartas de controle do banco de dados não tiveram uma satisfatória taxa de acertos em termos de reconhecimento de padrões. Isto não é fato novo e foi satisfatoriamente relatado na literatura técnica (Guo&Dooley,1992). O pré-processamento aqui utilizado, valendo-se de métodos de fácil computação teve a tarefa de eliminar as observações espúrias das cartas de controle, diminuindo o número de entradas para as redes neurais e aumentando em muito a eficiência das redes.

A escolha feita pela rede Fuzzy ARTMAP como passo inicial de experimentação, em detrimento da escolha da rede *Multilayer Perceptron* treinada por *Backpropagation* procura dar continuidade aos trabalhos de Guo&Dooley (1992), Hwang&Hubele (1993) e Tontini (1995). A rede treinada por *Backpropagation* (em uma de suas versões) foi já testada nos trabalhos de Cheng (1989) e seus resultados apesar de promissores, foram superados. A figura 4 mostra como os pontos das cartas de controle foram transformados e inicialmente utilizados nas redes neurais.

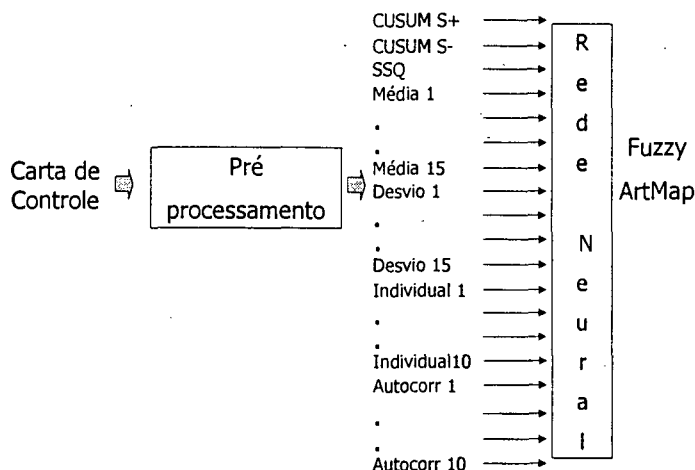


Figura 4: Processo experimental com as redes neurais evidenciando o pré-processamento

Os valores máximos das estatísticas da carta de somas acumuladas (CUSUM) tem a finalidade de auxiliar na monitorização do desvio da média. A Soma dos Quadrados dos Resíduos (SSQ) visa auxiliar na monitoração da variabilidade do processo e na discriminação entre os padrões de Mistura, Sistemático e Diminuição da Variabilidade. Os 60 pontos das cartas de controle são subdivididos em 15 faixas menores contendo 4 pontos por faixa onde são calculadas as Médias e Desvios Padrões com a finalidade de ajudar na identificação de padrões como mistura e sistemático. Os padrões aqui estudados tem uma grande amplitude e podem ocasionar um ponto fora de controle muito antes das estatísticas anteriores terem informação suficiente para sinalizar que tipo de padrão está ocorrendo. Os últimos 10 pontos individuais das cartas de controle estão, estreitamente relacionados com os padrões que se quer identificar e serão aqui utilizados. Tais pontos tem a finalidade de ajudar na identificação dos padrões de mistura e sistemático.

#### *Rede Fuzzy-ARTMAP*

A teoria de Ressonância Adaptativa, ou ART, foi introduzida como uma teoria sobre o processamento cognitivo de informações no cérebro humano. Essa teoria levou ao desenvolvimento de uma série de modelos de redes neurais capazes de um aprendizado não supervisionado para classificação de padrões em tempo real. Os modelos nessa família compreendem: a rede ART1, que pode aprender a categorizar padrões de entrada binários apresentados em ordem arbitrária; a rede ART2, que pode aprender a categorizar padrões de entrada analógicos ou binários; e a rede ART3, que pode fazer uma busca paralela, ou teste de hipóteses, em códigos com reconhecimento distribuído.

A rede ART1 foi usada no projeto de uma rede com arquitetura hierárquica chamada ARTMAP que tem aprendizado instantâneo, estabelecendo uma associação entre padrões binários de entrada com binários de saída. A rede Fuzzy-ART é uma generalização da rede ART1 para torná-la capaz de reconhecer padrões binários e analógicos, sendo muito mais simples que a ART2.

O desenvolvimento da rede Fuzzy-ARTMAP permitiu a adaptação da rede ARTMAP para a utilização de padrões analógicos tanto na entrada como na saída. A rede Fuzzy-ARTMAP é uma generalização da rede binária ARTMAP. Ela é capaz de um aprendizado supervisionado incremental, atualizando-se durante a operação sem “esquecer” o que já aprendeu anteriormente. A rede Fuzzy-ARTMAP pode ser empregada para classificação e/ou associação de padrões binários e/ou analógicos de entrada e saída com dimensão arbitrária.

A rede Fuzzy-ARTMAP incorpora dois módulos Fuzzy-ART: ARTa e ARTb, conectados através de um módulo inter-ART,  $F^{ab}$ , chamado Módulo de Ligação (*map field*). Os Módulos ARTa e ARTb funcionam da mesma maneira que a rede Fuzzy-ART, exceto pela interação com o módulo de ligação. O módulo de ligação é usado para fazer associações preditivas entre categorias nas redes ARTa e ARTb e para executar a pesquisa de similaridade, onde o nível de vigilância ( $\rho_a$ ) do módulo ARTa aumenta em resposta a um erro de previsão no módulo ARTb. A pesquisa de similaridade reconhece a estrutura de uma categoria de tal maneira que o erro de previsão não será repetido em apresentações subsequentes da mesma entrada. A operação da rede Fuzzy-ARTMAP está bem apresentada em Carpenter (1995)

O algoritmo inicialmente aqui utilizado foi codificado por Lars Liden (laliden@cns.bu.edu) em 1995 sob a forma de um conjunto de subrotinas em C (denominadas de *The Art Gallery*), que rodam em plataforma DOS/Windows e UNIX. É possível usar tais subrotinas em um código pessoal pois a DLL (*Dynamic Linked Library*) é disponibilizada. Suportando tanto aprendizagem supervisionada como não-supervisionada, o pacote computacional emprega dois tipos diferentes de redes: ART, para o modo não supervisionado, e ARTMAP para o modo supervisionado. Ambos os modos de redes são construídos de componentes ART's, os quais podem tomar diferentes formas, inclusive ART1 e Fuzzy-Art.



## 7. Medidas de Desempenho

Um conjunto extenso de simulações é necessário para se testar a capacidade da rede em detectar os diversos padrões não naturais das cartas de controle. Nesse sentido, o algoritmo da rede neural é repetidamente aplicado às sequências de dados e quando o padrão de interesse é detectado, o *run length* (número de pontos até a detecção do padrão não natural) é obtido. Com um número considerável de *run lengths* pode-se ter o cálculo do *ARL*.

Dois tipos de falsos alarmes podem ocorrer na utilização da maioria dos algoritmos que lidam com o reconhecimento dos padrões de CEP. O primeiro resulta quando o algoritmo detecta um padrão não natural qualquer quando ele de fato não existe (ou seja, o processo está sobre controle e o algoritmo diz que não está). O segundo é quando o algoritmo detecta um padrão não natural mas o padrão detectado não corresponde ao padrão alvo simulado (ou seja, há um erro na identificação do padrão, por exemplo, o algoritmo detecta um ciclo quando de fato há um desvio da média). Esse segundo falso alarme é frequentemente mais difícil de evitar pois muitos padrões, incluindo ciclos, contêm outros tipos de padrões como por exemplo as tendências.

O desempenho de um sistema de reconhecimento de padrões é usualmente avaliado por sua capacidade de classificação e generalização. A capacidade de classificação avalia se um sistema treinado tem aprendido a classificar corretamente os dados de um conjunto de treinamento enquanto a capacidade de generalização se refere a habilidade do sistema treinado em classificar corretamente dados similares que não foram vistos antes. Usualmente, a *performance* de uma carta de controle é medida pelo *ARL* e uma importante contribuição, proposta por Hwang & Hubele (1993), usa a expressão abaixo:

$$ARL_{tx} = ARL_t / R_t$$

onde  $R_t$  é a percentagem de padrões no qual o padrão não natural alvo foi detectado primeiramente e  $ARL_t$  é o *ARL* para detectar o padrão não natural alvo.

O valor de  $ARL_{tx}$  descreve em síntese uma medida de desempenho de quão boa a rede é capaz em detectar um determinado tipo de padrão. É desejável que o  $ARL_{tx}$  seja baixo para o estado do processo em que haja padrões não naturais e alto para o caso de padrões normais.

Assim, no teste do desempenho da rede neural, uma medida deve ser avaliada em termos de ambos os erros (tipo I e tipo II), isto é, tanto os padrões não naturais quanto os padrões naturais devem ser usados para testar e computar essa medida. Um sistema de reconhecimento de padrões não pode ser garantidamente útil na prática se ele não considera ambos os erros.

## 8. Resultados e Conclusões

Os resultados do reconhecimento de padrões dos gráficos de controle são surpreendentes se comparados ao reconhecimento feito por um especialista (um estudo pormenorizado está sendo feito nesse sentido) com taxas de acerto na ordem de 84%. Imagine a complexidade e o tempo para um especialista investigar padrões variantes com o tempo em 3200 cartas de controle!. Algumas preliminares conclusões são dadas a seguir:

- Devido a sua grande quantidade, a ordem de apresentação dos padrões de treinamento não evidenciou maiores discrepâncias nos resultados (teste de Fisher).
- O tempo de processamento, extremamente curto em relação ao treinamento por *Backpropagation*, mostrou ser uma importante vantagem nesse tipo de metodologia, ainda mais quando consideramos que a plasticidade é uma das características desse tipo de rede. Para tarefas semelhantes, em tempo real, intervalos pequenos de treinamento podem ser incorporados no sentido de detectar *deslocamentos de níveis* ou o aprendizado de novos padrões das séries temporais sob investigação (nesse caso o modelamento por meio de ARMA e ARIMA são extremamente complexos).

Algumas vantagens da rede Fuzzy-Artmap devem ser enfatizadas pois atendem a uma gama de processos que lidam com reconhecimento de padrões, principalmente aqueles que tratam com sistemas automatizados de manufatura, uma tendência dos processos atuais.

- Tratar simultaneamente diversos tipos de informações, provenientes de diversas fontes, analisando-as em tempo real;

- Adaptar-se a mudanças no processo e *aprender* com problemas e exemplos ocorridos durante sua operação, mesmo que esses exemplos não tenham sido estruturados;
- Estabelecer correlações entre um grande número de variáveis, mesmo que essas relações não sejam bem definidas e que haja interação entre as variáveis;
- Tratar situações novas, generalizando através da experiência passada;

## 9. Bibliografia

1. Schalkoff, R.J. (1990) *Artificial Intelligence*, McGraw-Hill, New York.
2. Luger, G. F.; Stubblefield, W. A. (1993), *Artificial Intelligence – Structures and Strategies for Complex Problem Solving*. Benjamin/Cummings, California.
3. Russel S.; Norvik, P. (1995) *Artificial Intelligence*, Prentice Hall New Jersey
4. Nelson L.S.(1985) Interpreting Shewhart X-bar Control Charts, *Journal of Quality Technology*, vol 17,2.
5. Hwang H.B.;Hubele N.F.,X-Bar Control Chart Pattern Identification Through Efficient Off-line Neural Network Training, *IIE Transactions*, Vol 25, 3, May 1993
6. Guo, Y.;Dooley, K. J.(1992) *Identification of Change Structure in Statistical Process Control*, *International Journal of Production Research*, vol 30 7 ;
7. Tontini G. (1995) *Automatização da Identificação de Padrões em Gráficos de Controle Estatístico de Processos (CEP) Através de Redes Neurais com Lógica Difusa* - Tese de Doutorado UFSC;
8. Mittag, H. J.; Rinne, H. (1993 ) *Statistical methods of Quality Assurance* Chapman&Hall -Glasgow -393-44;
9. Cheng, C.S. (1997) *A neural Network Approach for the analysis of Control Chart Patterns*- *Int. J. Prod. Res.*, Vol.35, No 3, 667-697.
10. Carpenter G. A; Grossberg S. (1995) Fuzzy-ARTMAP: A Synthesis of Neural Networks and Fuzzy Logic for Supervised Categorization and Nonstationary Prediction; In *Fuzzy Sets, Neural Networks, and Soft Computing*. Yager, R.R. and Zadeh, L. A;

---

## **MÉTODOS DE PREVISÃO USANDO A SÉRIE ECONOMÉTRICA DE NELSON-PLOSSER: UM ESTUDO COMPARATIVO**

**Robert Wayne Samohyl**

UFSC - Departamento de Engenharia de Produção e Sistemas - e-mail: [samohyl@eps.ufsc.br](mailto:samohyl@eps.ufsc.br)

**Pedro Paulo Balestrassi**

EFEI –Escola Federal de Engenharia de Itajubá - e-mail: [pedro@eps.ufsc.br](mailto:pedro@eps.ufsc.br)

**Roberto Meurer**

UFSC – Departamento de Ciências Econômicas - e-mail: [rmeurer@mbox1.ufsc.br](mailto:rmeurer@mbox1.ufsc.br)

**Abstract:** *The time series forecasting is one of the most important objective in econometric and production Engineering and many mathematical methods have been used in this domain. The Artificial Neural Networks (ANN) and the Econometric Models are two of these proeminent methods. The main goal of this paper is to compare these methods using the classical econometric Nelson-Plosser data.*

**Área:** 10-Gestão da Informação (10.1-Redes Neurais)

**Keywords:** *Neural Network, Econometric, Time Series*

### **1. Introdução**

A previsão de séries temporais é um dos fatores mais importantes em econometria e em engenharia de produção e diversos métodos matemáticos tem sido empregados nessa tarefa. As Redes Neurais Artificiais (RNA) e os Modelos Econométricos são dois desses métodos.

Duas dessas redes neurais, a rede *Multilayer Perceptron* treinada por *Backpropagation* (representada aqui simplesmente por *Backpropagation*) e a rede com Função de Base Radial (RBF), são aqui utilizadas (conforme 2ª seção). Os modelos autoregressivos, usando testes de raízes unitárias e co-integração, são também aqui empregados comparativamente (3ª seção). Na 4ª seção, resultados e conclusões, os

valores de previsão são fornecidos para os métodos utilizados e algumas considerações são feitas.

É importante ressaltar que existe um paralelo que pode ser feito entre métodos estatísticos e redes neurais, utilizados nesse texto, conforme mostra a tabela 1.

Estatística	Redes Neurais
Modelo	Rede
Estimação	Aprendizagem
Regressão	Aprendizagem supervisionado
Interpolação	Generalização
Observações	Conjunto de treinamento
Parâmetros	Pesos
Variáveis independentes	Entradas
Variáveis dependentes	Saídas
Regressão de Ridge	Decaimento dos pesos

Tabela 1: Terminologia correspondente entre estatística e redes neurais

A série clássica de Nelson-Plosser, representando os dados macroeconômicos dos EUA (obtida em [1]), possui as seguintes variáveis:

RGNP	Produto Interno Bruto Real
GNP	Produto Interno Bruto
PCRGNP	Produto Interno Bruto Real Per Capita
IP	Produção Industrial
EMP	Emprego
UN	Taxa de Desemprego
PRGNP	Deflator do Produto Interno Bruto
CPI	Preço ao Consumidor
WG	Salário
RWG	Salário Real
M	Estoque Monetário
VEL	Velocidade
BND	Produção Vinculada
SP500	Preços de Estoque Comum

Vale ressaltar que a variável escolhida para ter seus valores previstos foi a CPI (Preço ao Consumidor) tendo suas 4 últimas observações utilizadas para avaliação dos métodos.

Todo esse trabalho foi desenvolvido no sentido de que seus resultados possam ser facilmente reproduzidos, usando os mesmos programas computacionais, e estimular um estudo de *Benchmark* com respeito aos métodos de previsão disponíveis.

## 2. Modelo Econométrico

A utilização de modelos econométricos de uma forma dinâmica por meio de regressões é atualmente descrito como um dos tópicos mais avançados em previsão de séries temporais [1]. Diversos fatores são levados em consideração nesse tipo de análise: heteroscedasticidade, multicolinearidade, raízes unitárias, correção de erros, co-integração, etc. Para a série de dados em questão foi utilizada a metodologia do programa computacional PcGive 8.0.

Uma das suposições mais frequentes que se faz a respeito de uma série temporal é de que ela seja estacionária, ou seja, ela se desenvolve no tempo aleatoriamente em torno de uma média constante, refletindo alguma forma de equilíbrio estável. Todavia, a maior parte das séries que encontramos na prática apresentam alguma forma de não-estacionaridade. Os modelos de auto-regressão, podem ser utilizados para descrever de maneira satisfatória séries estacionárias. Séries temporais que não se comportam de forma estacionária devem ser transformadas. A transformação mais comum consiste em tomar diferenças sucessivas da série original, até que se obtenha a estacionaridade. As duas principais razões para se efetuar transformações são: estabilizar a variância e conseguir a normalidade.

Uma rápida inspeção visual dos gráficos da série de Nelson-Plosser permite concluir que as variáveis são não-estacionárias. Para investigar a estacionaridade de uma série três métodos são frequentemente utilizados: (i) o correlograma, (ii) o teste da raiz unitária e (iii) a estatística de Durbin-Watson. O correlograma é essencialmente visual e representa a função de correlação serial das variáveis. Ele nos fornece sinais sobre o tipo de transformação a ser feita sobre os dados.

Tomando-se a primeira diferença de todas as variáveis (representado aqui pela letra D acrescida à variável) e a segunda diferença da variável M (representado por DDM), o teste da raiz unitária de Dickey-Fuller (DF) e Dickey-Fuller Ampliado (ADF) rejeita a hipótese nula da não-estacionaridade ( $H_0$ : existe raiz unitária) a um nível pequeno de significância (5%). Os resultados do teste encontram-se na tabela 2.

VARIÁVEIS	I(0)				I(1)			
	S/ Tendência		C/ Tendência		S/ Tendência		C/ Tendência	
	DF	ADF(1)	DF	ADF(1)	DF	ADF(1)	DF	ADF(1)
DRGNP	-4.6425	-3.8476	-5.0875	-4.3532				
DGNP	-2.8586	-1.8799	-4.6948	-3.6125				
DPCRGNP	-5.0266	-4.4000	-5.0818	-4.4855				
DIP	-6.0244	-4.7869	-6.5003	-5.4028				
DEMP	-4.7189	-4.8808	-4.7298	-4.9133				
DUN	-5.3988	-5.4426	-5.3489	-5.3935				
DPRGNP	-4.5900	-3.6882	-4.8535	-3.9763				
DCPI	-3.9228	-4.2780	-4.0624	-4.4487				
DWG	-3.1131	-2.8691	-4.3670	-4.3660				
DRWG	-4.8484	-4.3090	-4.8756	-4.3712				
DM	-1.7586	-1.8369	-2.7079	-2.8689	-7.2250	-4.9821	-7.1527	-4.9034
DVEL	-6.4946	5.5140	-6.4775	-5.5209				
DBND	-5.4523	-2.2874	-6.1080	-2.8543				
DSP500	-5.4123	-4.4858	-5.5756	-4.8246				

Tabela 2- Teste de raízes unitárias (Nota: Todas as equações incluem um termo constante. Os valores críticos ao nível de significância de 5% são: sem tendência, -2.9109; com tendência -3.4862; período de 1909-1970.)

Na tabela 3, são calculados os coeficientes autoregressivos do modelo após a correção da estacionaridade. Foram feitos sucessivos testes a partir de um modelo genérico com 2 *lags* para cada variável diferenciada. Os termos irrelevantes do modelo foram gradualmente retirados (usando o critério F de Fisher) e algumas estatísticas de controle foram apresentadas

Os valores encontrados para o teste de Fisher,  $F(18, 35)=130.89$ , indicam significativamente que pelo menos uma das variáveis independentes do modelo explica a variável dependente DCPI. O teste Durbin-Watson,  $DW=2.04$ , mostra a ausência de correlação serial, estando o seu valor bem próximo de seu valor ideal.

Variável	Coefficient	Erro-padrão	t-value	t-prob	R <sup>2</sup> Parcial
Constante	0.45395	0.13233	3.430	0.0016	0.2516
DCPI_1	0.68266	0.10502	6.500	0.0000	0.5469
DRGNP_1	-0.17477	0.058290	-2.998	0.0050	0.2044
DGNP_1	0.10343	0.035895	2.881	0.0067	0.1917
DPCRGNP	0.0050872	0.0021221	2.397	0.0220	0.1410
DPCRGNP_1	0.016074	0.0055445	2.899	0.0064	0.1936
DIP_2	-0.18105	0.038799	-4.666	0.0000	0.3835
DEMP	-0.42899	0.14903	-2.879	0.0068	0.1914
DEMP_2	0.23737	0.069310	3.425	0.0016	0.2510
DUN	-0.17560	0.066886	-2.625	0.0127	0.1645
DPRGNP	0.46504	0.047633	9.763	0.0000	0.7314
DPRGNP_1	-0.28090	0.074879	-3.751	0.0006	0.2868
DWG	0.012291	0.0017186	7.152	0.0000	0.5937
DWG_1	-0.017193	0.0036356	-4.729	0.0000	0.3899
DRWG	-0.70149	0.12062	-5.816	0.0000	0.4914
DRWG_1	0.91608	0.22316	4.105	0.0002	0.3250
DVEL_1	.6448	0.96312	2.746	0.0095	0.1773
DBND_1	0.80827	0.30781	2.626	0.0127	0.1646
DDM_1	-0.064376	0.024935	-2.582	0.0142	0.1600

Tabela 3: Modelamento de DCPI por Mínimos Quadrados Recursivos

Os coeficientes calculados mostram-se de acordo com a teoria econômica. O teste de estabilidade dos parâmetros de Chow,  $F(4, 35) = 1.6729$  [0.1783], revela a não-existência de uma diferença significativa entre os valores observados e projetados.

Quanto a normalidade dos resíduos, um aspecto importante nesse tipo de modelamento, os valores da estatística de aderência aceitam a hipótese de que a distribuição dos resíduos é gaussiana ( $\chi^2(2) = 0.067622$  [0.9668]). Além disso não houve indícios de heteroscedasticidade condicional autoregressiva, ou seja, a variância dos resíduos permanece constante ao longo do tempo (ARCH 1  $F(1,33) = 0.000239$  [0.9880]). A forma funcional encontrada para o modelo pode ser escrita como uma combinação linear das variáveis independentes (RESET  $F(1,34) = 1.9754$  [0.1689]).

Foram ainda realizados os testes de co-integração verificando-se que apenas a variável: DDM não era co-integrada com a sua variável dependente. Feito o modelo de mecanismo de correção de erros, os resultados de previsões encontrados (por serem previsões a curto prazo) não diferiram do modelo formulado sem o termo de correção de erro. Finalmente, os resultados de previsão, objeto desse trabalho, podem ser vistos na figura 1. Os valores numéricos são avaliados na seção 4.






Figura 1: Intervalos de previsão dos 4 últimos anos

### 3. Redes Neurais Artificiais

Os resultados da previsão da série de Nelson-Plosser através de RNA, foram aqui obtidos usando *Backpropagation* e RBF. Para tanto foi utilizado o programa MatLab 4.2 com pequenas modificações em algumas rotinas da *Toolbox* de redes neurais. MatLab é marca registrada da The MathWorks Inc. Não é objetivo deste texto descrever a teoria matemática de RNA que pode ser encontrada facilmente em livros da área.

O formato dos dados (de treinamento e teste) das redes neurais está exemplificado abaixo (houve aqui uma transformação linear da série):

Entrada  
 0.0240 (RGNP)  
 0.0066 (GNP)  
 0.0918 (PCRGNP)  
 0.0248 (IP)  
 0.0690 (EMP)  
 0.1308 (UN)  
 0.0188 (PRGNP)  
 0.0119 (WG)  
 0.0366 (RWG)  
 0.0077 (M)  
 0.7557 (VEL)  
 0.3037 (BND)

Saída (para treinamento)  
 0.0193 (CPI)

Os dados foram transformados linearmente obtendo-se a amplitude de cada série e dividindo-se cada observação por essa amplitude.

0.0289 (SP500)

Algumas observações a respeito da aplicação de redes neurais são aqui ressaltadas (para um maior aprofundamento uma boa referência é dada em [4]):

- É demonstrado que as redes neurais do tipo *feedforward* são aproximadores de função universais (teoremas de Kolmogorov, Sprecher e Hecht-Nielsen [4]). Esse resultado teórico é acompanhado por investigações numéricas que tem mostrado experimentalmente a grande capacidade de redes neurais relativamente simples em aproximar mapas não-lineares. Esses achados estimulam a aplicação de redes neurais no campo de séries temporais não lineares.
- No projeto de uma rede neural os resultados finais de desempenho, e especialmente a sua capacidade de generalização da solução, dependem da configuração inicial dos parâmetros da rede neural. Isso é, via de regra, baseado em heurística e muitas vezes pode tornar o método extremamente complexo.
- Uma rede neural pode construir um modelo linear a partir de uma função de transferência não-linear. Se a equação de uma rede neural for (por exemplo) dada pela equação:

$$x_t = w_0 + \sum_{l=1}^H w_l \tanh\left(\sum_{k=1}^I a_{lk} x_{t-k} + a_{l0}\right)$$

( $H$ : número de camadas ocultas,  $I$ : número de entradas da rede)

para pequenos valores de  $|x|$ ,  $\tanh(x)$  é aproximadamente igual a  $x$  e a equação acima pode ser re-escrita em forma de um modelo autoregressivo de ordem  $i$ :

$$x_t = w_0 + \sum_{k=1}^I \left( \sum_{l=1}^H w_l a_{lk} \right) x_{t-k} + \sum_{l=1}^H w_l a_{l0}$$

### ***Backpropagation***

A rede neural apresentada na figura 2 pode ser usada como um aproximador universal de funções. Ela pode aproximar qualquer função com um número finito de descontinuidades.




Figura 2: Rede *Multilayer Perceptron (feedforward)*

O processo de aprendizagem da rede *Backpropagation* foi implementado utilizando o código do programa em MatLab 4.2 usando as funções INITFF, TRAINBPX e SIMUFF como descrito a seguir.

```
load P.txt % P define 13 entradas de treinamento com vetores de diferenças minimizados
load T.txt % Alvo de valores minimizados (CPI)
S1= 20;      % Uma camada oculta com S1 neurônios

% Inicialização dos pesos da rede

PIni=[0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1]
TIni=[0 1];
[w1,b1,w2,b2] = initff(PIni,S1,'tansig',TIni,'tansig'); % Função de Inicialização da Rede

% Treinamento da rede
df = 25; % Frequência de atualização do gráfico de erros.
me = 3000; % Máximo número de épocas a ser treinada
eg = 0.001; % SSE
lr = 0.01; % Taxa de Aprendizagem
tp = [df me eg lr]; % Uso de Backpropagation com Taxa de Aprendizagem
[w1,b1,w2,b2,ep,tr] = trainbpx(w1,b1,'tansig',w2,b2,'purelin',P,T,tp); % Função de Treinamento da Rede

% Teste da Rede (Previsão e Apresentação do Resultado)

load TesIn.txt % Vetor de teste de entrada
load Alvo.txt % Alvo do teste (CPI)
for i=1:4
teste(i) = simuff(TesIn(:,i),w1,b1,'tansig',w2,b2,'purelin'); % Função de Teste da Rede
Previsão(i)= teste(i)*88.3+28; % Fator de Correção Linear da Minimização da série CPI
disp([Alvo(i), Previsão(i),(Alvo(i)- Previsão(i)), (Alvo(i)- Previsão(i))/Alvo(i)]);
end;
disp('Fim')
```

## RBF

As funções de base radiais são uma classe especial de funções. A característica específica desse tipo de função é que a resposta diminui (ou aumenta) monotonicamente com a distância de um ponto central. Tal ponto, uma distância escalar e a forma da função de base radial são parâmetros do modelo que devem ser fixados como se fossem lineares.

Desde os trabalhos de Broomhead e Lowe em 1988 as funções de base radial tem sido tradicionalmente relacionadas às RNA com apenas uma camada intermediária. Um bom texto (com código de programa computacional) sobre RBF pode ser livremente obtido no endereço eletrônico: <http://www.cns.ed.ac.uk/people/mark>

Uma enorme vantagem desse tipo de rede sobre a *Backpropagation* é que o projeto de sua rede é muito mais simples em função da definição heurística de um número bem menor de parâmetros.

O programa em MatLab usando as funções SOLVERB e SIMURB é dado a seguir:

```
load P.txt % P define 13 entradas de treinamento com vetores de diferenças minimizados
load T.txt % Alvo de valores minimizados (CPI)
df = 10;      % Frequência de atualização do gráfico de erros.
mn = 20;      % Máximo Número de Neurônios
eg = 0.01;    % SSE.
sc = 100;     % Constante de Alargamento para a Função de Base Radial
tp = [df mn eg sc];
[w1,b1,w2,b2,nr,tr] = solverb(P,T,tp); % Função de Treinamento da Função de Base Radial

% Teste da Rede (Previsão e Apresentação do Resultado)

load TesIn.txt % Vetor de teste de entrada
load Alvo.txt % Alvo do teste (CPI)
for i=1:4
teste(i) = simurb(TesIn(:,1),w1,b1,w2,b2); % Função de Teste da Função de Base Radial
Previsão(i) = teste(i)*88.3+28; % Fator de Correção Linear da Minimização da série CPI
disp([Alvo(i), Previsão(i),(Alvo(i)- Previsão(i)), (Alvo(i)- Previsão(i))/Alvo(i)]);
end;
disp('Fim')
```

4. Resultados e Conclusões

A tabela 4 apresenta os resultados de previsão para as últimas 4 observações da série de Nelson-Plosser. Pode-se perceber que os valores são bem próximos e se revelam estatisticamente iguais.

	Modelo Econométrico			Backpropagation			RBF		
Real	Previsto	Diferença	Difer./Real	Previsto	Diferença	Difer./Real	Previsto	Diferença	Difer./Real
100.0	100.57	-0.57	-0.0057	100.10	-0.10	-0.0010	98.69	1.30	0.0130
104.2	105.60	-1.40	-0.0135	105.30	-1.10	-0.0106	103.36	0.83	0.0080
109.8	111.22	-1.42	-0.0129	110.55	-0.75	-0.0069	108.60	1.19	0.0109
116.3	117.71	-1.41	-0.0122	116.95	-0.65	-0.0056	116.96	-0.66	-0.0057

Tabela 4: Resultados de previsão

No intuito de estabelecer um estudo comparativo entre os métodos, algumas vantagens e desvantagens podem aqui ser relacionadas:

- *Redes Neurais*
  - *Vantagens*
    - Menor erro de previsão (não estatisticamente significativo);
    - Menor dependência do econometrista;
    - Existem poucas restrições à morfologia dos dados;
    - Rapidez nos cálculos;
    - Pode frequentemente funcionar como uma “caixa preta”;
    - Não necessidade de definição da variável endógena
  - *Desvantagens*
    - Pode frequentemente funcionar como uma “caixa preta”;
    - Não há, frequentemente, um controle gráfico das variáveis;
    - Não há, frequentemente, intervalos de confiança para estimativas

- *Modelo Econométrico*

- *Vantagens*

- A equação do modelo é obtida;
    - Os intervalos de confiança das estimativas são fornecidos;
    - Há um acompanhamento gráfico das variáveis modeladas;
    - Rapidez nos cálculos;

- *Desvantagens*

- Existem inúmeras condições iniciais que devem ser observadas;
    - Existe um grande número de testes de hipóteses;
    - Tem maior erro de previsão (não estatisticamente significativo);
    - Não pode frequentemente funcionar como uma “caixa preta”;

### *Conclusões*

A rede com Função de Base Radial, sendo considerada como *aproximador universal* teve o desempenho ligeiramente superior (não significativo estatisticamente) com o menor tempo de treinamento. O número de parâmetros (definidos heurísticamente) é bem menor nesse tipo de rede.

A rede *Multilayer Perceptron* com treinamento por *Backpropagation* teve resultados similares à rede com Função de Base Radial mas com um número de parâmetros superior e um tempo de treinamento também superior.

O funcionamento do método como uma *caixa preta* pode ser ou não uma vantagem, dependendo do nível de conhecimento do usuário.

O modelo econométrico permitiu um maior conhecimento das variáveis envolvidas na série, permitindo (a posteriori) uma melhor definição sobre o tipo de transformação a ser efetuada sobre os dados para a entrada das redes neurais.

Uma importante conclusão do trabalho é que ambos os métodos atuantes conjuntamente (melhor que separadamente) formam uma poderosa ferramenta de previsão econométrica. O pré-processamento dos dados é extremamente importante em qualquer tipo de rede neural e isso pode ser viabilizado pelo modelo econométrico.

## 5. Bibliografia

- [01] MADALLA, G.S. **Introduction to Econometrics**. New Jersey, Prentice-Hall, Inc. 1992
- [02] DOORNICK, J. A.; HENDRY, D. F. **PcGive 8.0 An Interactive Econometric Modelling System**. London, Chapman & Hall, 1995.
- [03] KUAN, C.M.; WHITE, H. "Artificial Neural Networks: An Econometric Perspective" *Econometric Reviews*, 13(1), 1994.
- [04] FAUSSET, L. V. **Fundamentals of Neural Networks** New Jersey, Prentice-Hall, Inc. 1994